



**LEUPHANA**  
UNIVERSITÄT LÜNEBURG

Einsatz von künstlicher Intelligenz zur  
Prozessoptimierung und Steigerung der  
Ressourceneffizienz in kleinen und mittleren  
Unternehmen

Der Fakultät Nachhaltigkeit  
der Leuphana Universität Lüneburg zur Erlangung des Grades

Doktorin der Naturwissenschaften

– Dr. rer. nat. –

vorgelegte Dissertation von Martina Willenbacher  
geboren am 11. Februar 1979 in Stralsund

Eingereicht am:

Erstbetreuer und Erstgutachter:

**Prof. Dr. Andreas Möller**

*Leuphana Universität Lüneburg,  
Institut für Nachhaltige Chemie*

Zweitgutachter:

**Prof. Dr. Volker Wohlgemuth**

*Hochschule für Technik und Wirtschaft Berlin,  
Fachbereich 2 - Ingenieurwissenschaften*

Drittgutachter:

**Prof. Dr. Dieter Kranzlmüller**

*Ludwig-Maximilians-Universität München,  
Institut für Informatik*

Die einzelnen Beiträge des kumulativen Dissertationsvorhabens sind oder werden wie folgt veröffentlicht:

1. Willenbacher, M.; Wohlgemuth, V.; Risch, L. Neural Networks for Energy Optimization of Production Processes in Small and Medium Sized Enterprises. In: Wohlgemuth, V.; Naumann, S.; Behrens, G.; Arndt, H.-K.; Höb, M. (eds). *Advances and New Trends in Environmental Informatics*, pp. 129–145. Springer International Publishing. Cham (2023). doi: 10.1007/978-3-031-18311-9\_8
2. Willenbacher, M.; Wohlgemuth, V. Rebound Effects in the Use of Rare Earth Metals in ICT. *IJESNR* 30 (1) (2022). doi: 10.19080/IJESNR.2022.30.556277
3. Willenbacher, M.; Scholten, J.; Wohlgemuth, V. Machine Learning for Optimization of Energy and Plastic Consumption in the Production of Thermoplastic Parts in SME. *Sustainability* 2021, 13 (12): 6800 (2021). doi: 10.3390/su13126800

Veröffentlichungsjahr: 2023

Veröffentlicht im Onlineangebot der Universitätsbibliothek unter der URL:  
<http://www.leuphana.de/ub>

## Zusammenfassung

Ein wichtiger Treiber für Steigerung der Produktivität in verarbeitenden kleinen und mittleren Unternehmen (KMU) ist die Digitalisierung von Produktionsabläufen. Die damit verbundene Volumensteigerung von Daten bietet ein enormes Potenzial für die Analyse und Optimierung von Prozessen. Diese Daten aus einer Vielzahl von Geräten und Systemen erhöhen jedoch den Bedarf an intelligenten, dynamischen Analysemodellen. Allerdings verfügen KMU über einen geringen bis sehr geringen Digitalisierungsgrad. Das resultiert aus einer Kombination verschiedener Faktoren, wie knappe Finanz- und Personalressourcen für Forschungs- und Entwicklungsaktivitäten, fehlende Expertise im IT-Bereich und geringe Bereitschaft zur Einführung neuartiger digitaler Technologien und künstlicher Intelligenz. Weiterhin sind die Produktionsprozesse verarbeitender KMU sehr individuell und teilweise hochspezialisiert, sodass sich bestehende KI-Module nicht ohne erhöhten Anpassungsaufwand in die bestehende Produktionsstruktur adaptiert werden können. Im Rahmen dieses Promotionsvorhabens wurden zwei Machine Learning-Verfahren für den praktischen Einsatz in einem verarbeitenden KMU entwickelt. Ziel war das Erkennen von Zusammenhängen zwischen Energieverbrauch und Ausschuss und den Maschineneinstellungen sowie das Auffinden optimaler Parametereinstellungen, um die Effizienz von Energie und steigern und die Abfallquote zu senken. Dabei lag der Fokus auf der Einfachheit der Lösung sowie der leichten Adaptierbarkeit auf sich ändernde Produktionsvorgänge. Ausgangspunkt war die Einrichtung einer einheitlichen Datenbasis für den Produktionsbereich des Unternehmens, um vollständige Maschinenprotokolle zu zentralisieren. Das erste umgesetzte Verfahren war der Random Forest-Algorithmus, eine ML-Methode für die Modellierung von Ensemble-Entscheidungsbäumen. Als zweite ML-Methode wurde ein künstliches neuronales Netz (KNN) entwickelt. Beide Verfahren wurde mit KI-Erklärmodellen interpretiert, um die Ergebnisse nachzuvollziehen. Bei der Validierung der beiden Modelle zeigten sich größere Unterschiede in der Genauigkeit und der empfohlenen Parametereinstellungen. Dies lässt sich auf die unterschiedlichen Berechnungsmethoden der Algorithmen zurückführen. Es konnte

jedoch gezeigt werden, dass auch mit weniger komplexen KI-Verfahren, deren Auswahl auf einer eindeutigen Zieldefinition basieren, deutliche Produktivitätssteigerungen erreicht werden können. Durch ganzheitliche Digitalisierung und die dadurch zu verarbeitenden Daten mit Verfahren der KI können entscheidende Schritte für eine ressourceneffizientere Produktion vollbracht werden. Ein wichtiger Aspekt dabei ist dennoch, dass die dafür nötigen Informations- und Kommunikationstechnologie-Komponenten einen steigenden Rohstoffbedarf erzeugen und einen beträchtlichen Teil des Elektroschrotts verantworten. Diese kritischen Aspekte der Digitalisierung wurden daher ebenfalls im Rahmen der Promotion betrachtet. Mit dem Fokus auf Seltenerdmetallen wurden die Umweltauswirkungen von der Gewinnung bis zur Entsorgung untersucht und ein Rückschluss auf den produktionsseitigen Rebound-Effekt gezogen.

## **Abstract**

An important driver for increasing productivity in manufacturing small and medium sized enterprises (SMEs) is the digitization and digitalization of production processes. The associated increase in data volume offers enormous potential for the analysis and optimization of processes. Data from a variety of devices and systems increases the need for intelligent, dynamic analysis models. However, SMEs have a low to very low degree of digitalization. This is the result of a combination of various factors, such as scarce financial and human resources for research and development activities, a lack of IT expertise and a reluctance to introduce new digital technologies and artificial intelligence. Furthermore, the production processes of processing SMEs are very individual and sometimes highly specialized, so that existing AI modules cannot be adapted to the existing production structure without increased adaptation effort. As part of this doctoral project, two machine learning methods were developed for practical use in a processing SME. The aim was to identify connections between energy consumption and plastic scrap and the machine settings as well as to find optimal parameter settings to increase energy efficiency and reduce the waste rate. The focus was on the simplicity of the solution and the easy adaptability to changing production

processes. The starting point was to set up a uniform database for the company's production area to centralize complete machine logs. The first method implemented was the Random Forest algorithm, an ML method for modeling ensemble decision trees. An artificial neural network (ANN) was developed as the second ML method. Both methods were interpreted with AI explanatory models to understand the results. Validation of the two models revealed major differences in accuracy and recommended parameter settings. This can be attributed to the different calculation methods of the algorithms. It could be shown that significant increases in productivity can also be achieved with less complex AI processes, the selection of which is based on a clear definition of goals. Holistic digitalization and the data to be processed as a result with AI processes can be used to take decisive steps towards more resource-efficient production. Nevertheless, an important aspect is that the information and communication technology components required for this generate an increasing demand for raw materials and are responsible for a considerable part of the electronic waste. These critical aspects of digitalization were therefore also considered as part of the doctorate. With a focus on rare earth metals, the environmental impact from extraction to disposal was examined and conclusions were drawn about the production-side rebound effect.

## Danksagung

Die vorliegende Dissertation wurde an der Fakultät Nachhaltigkeit der Leuphana Universität Lüneburg in Kooperation mit dem Fachbereich Ingenieurwissenschaften der Hochschule für Technik und Wirtschaft Berlin angefertigt. An dieser Stelle möchte ich mich bei all denen bedanken, die mich auf vielfältige Weise bei meiner Arbeit unterstützten:

- Ich danke Herrn Prof. Dr. Andreas Möller, der mir die Möglichkeit gegeben hat, diese Arbeit an der Leuphana Universität Lüneburg durchzuführen, für die Überlassung des Themas sowie die Betreuung bei der Anfertigung der Arbeit.
- Mein außerordentlicher Dank gilt Prof. Dr. Volker Wohlgemuth für die wertvolle Unterstützung auf inhaltlicher und methodischer Ebene sowie seinen hohen persönlichen Einsatz, der zum Gelingen dieser Arbeit erheblich beigetragen hat. Vielen Dank für das Vertrauen in meine Arbeit und die Möglichkeit, mich dieser beruflichen und persönlichen Herausforderung zu stellen!
- Mein herzlicher Dank gilt Herrn Prof. Dr. Dieter Kranzmüller der Ludwig-Maximilians-Universität München, der sich sofort bereit erklärt hat, die externe Begutachtung meiner Promotion zu übernehmen.
- Ich danke den Kollegen des Fachbereichs Ingenieurwissenschaften der Hochschule für Technik und Wirtschaft Berlin, welche mich während meiner Arbeit an der HTW bei der Bearbeitung der Dissertation mit zahlreichen Hinweisen und Ratschläge unterstützten.
- Nicht zuletzt danke ich meiner Familie, die mich während der gesamten Promotionszeit unterstützte und motivierte. Vielen Dank für eure Geduld, euer Verständnis und die liebevolle Fürsorge!

## INHALTSVERZEICHNIS

Zusammenfassung.....	IV
Abstract.....	V
Danksagung.....	VII
Abbildungsverzeichnis.....	IX
Tabellenverzeichnis.....	X
Abkürzungsverzeichnis.....	XI
1. Einleitung und Motivation.....	1
2. Theoretische Grundlagen von künstlicher Intelligenz.....	8
3. Zielsetzung und Fragestellung.....	15
4. Forschungsdesign.....	17
5. Publikationsübersicht: Methoden und Ergebnisse.....	26
6. Zusammenfassung und aktuelle Herausforderungen.....	36
7. Kumulativer Teil der Dissertation.....	45
1: Machine Learning for Optimization of Energy and Plastic Consumption in the Production of Thermoplastic Parts in SME.....	45
2: Neural Networks for Energy Optimization of Production Processes in Small and Medium Sized Enterprises.....	65
3: Rebound Effects in the Use of Rare Earth Metals in ICT.....	82
8. Publikationsliste.....	96
Literaturverzeichnis.....	98
Anhang A: Beitrag des Autors zu den Veröffentlichungen.....	103
Anhang B: Betreute studentische Arbeiten.....	106

## Abbildungsverzeichnis

Abbildung 1: Prozentualer Anteil der KMU, Mitarbeiter in KMU sowie Wertzuwachs von KMU in Deutschland und in der EU 2021/2022 (European Commission et al., 2022) .....	1
Abbildung 2: Digitalisierungsgrad von KMU und GU in 2022 (Institut für Mittelstandsforschung Bonn, 2022) .....	2
Abbildung 3: Genutzte Kommunikationswege zwischen Maschinen und Datenbanken in KMU (Eigene Darstellung) .....	5
Abbildung 4: Material- und Energieverbrauch für die Produktion einer Tonne seltener Erden (Talens Peiró & Villalba Méndez, 2013) .....	7
Abbildung 5: Information Systems Research Framework (Hevner et al., 2004).....	18
Abbildung 6: IT Interaction Modell (Silver et al., 1995) .....	19
Abbildung 7: Konzeptioneller Ablauf der Einführung von KI in KMU (Eigene Darstellung).....	21
Abbildung 8: Prozess des RF-Modells (Eigene Darstellung) .....	24
Abbildung 9: Prozess des KNN (Eigene Darstellung).....	24
Abbildung 10: DSR-Prozess der Dissertation im IS Research Framework nach Hevner (Hevner et al., 2004).....	25
Abbildung 11: Zusammenhang der Publikationen (Eigene Darstellung, erstellt mit Unterstützung von DALL·E 2).....	27
Abbildung 12: Ergebnisse des RF-Algorithmus für M64.....	38
Abbildung 13: Ergebnisse des KNN für M64 .....	38
Abbildung 14: Ergebnisse des RF-Algorithmus für M67.....	39
Abbildung 15: Ergebnisse des KNN für M67 .....	39
Abbildung 16: Ergebnisse des RF-Algorithmus für M68.....	40
Abbildung 17: Ergebnisse des RF-Algorithmus für M69.....	41
Abbildung 18: Ergebnisse des KNN für M69 .....	41

## Tabellenverzeichnis

Tabelle 1: Überblick über ML-Algorithmen.....	12
Tabelle 2: Publikation 1: “Machine Learning for Optimization of Energy and Plastic Consumption in the Production of Thermoplastic Parts in SME” .....	27
Tabelle 3: Ergebnisse der RF-Modelle.....	28
Tabelle 4: Prognostizierte Energieersparnis pro Jahr (ML) .....	32
Tabelle 5: Publikation 2: “Neural Networks for Energy Optimization of Production Processes in Small and Medium Sized Enterprises” .....	32
Tabelle 6: Ergebnisse des KNN.....	33
Tabelle 7: Prognostizierte Energieersparnis pro Jahr (KNN) .....	35
Tabelle 8: Publikation 3: “Rebound Effects in the Use of Rare Earth Metals in ICT” .....	35
Tabelle 9: Ausgangsdaten der einzelnen Maschinen .....	36
Tabelle 10: Überblick über den Beitrag des Autors zu den Veröffentlichungen .....	103

## **Abkürzungsverzeichnis**

AI	Artificial Intelligence (Künstliche Intelligenz)
AIX	Explainable AI
DSR	Design Science Research
EJ	Exajoule
FuE	Forschung und Entwicklung
GJ	Gigajoule
GU	Großunternehmen
IDE	Integrated Development Environment (Integrierte Entwicklungsumgebung)
IKT	Informations- und Kommunikationstechnologie
KI	Künstliche Intelligenz
KMU	Kleine und mittlere Unternehmen
KNN	Künstliches neuronales Netz
LIME	Local Interpretable Model-agnostic Explanations
ML	Machine Learning (Maschinelles Lernen)
RF	Random Forest
VPN	Virtual Private Network

## 1. Einleitung und Motivation

Kleine und mittlere Unternehmen (KMU) sind in Deutschland und auch in den Ländern der EU der bedeutendste wirtschaftliche Treiber. In Deutschland gibt es ca. 2,5 Millionen KMU, die mit 42 % an der gesamten Wertschöpfung des Landes beteiligt sind und 55 % der sozialpflichtigen Arbeitnehmer beschäftigen (Statistisches Bundesamt, 2023).

**KMU-Definition der Europäischen Kommission:** Unternehmen mit bis zu 249 Beschäftigten und einem Umsatz von höchstens 50 Millionen Euro oder einer Bilanzsumme von maximal 43 Millionen Euro (*Empfehlung der Kommission vom 6. Mai 2003 betreffend die Definition der Kleinstunternehmen sowie der kleinen und mittleren Unternehmen.* Europäische Kommission, 2003)

Im Jahr 2020 erwirtschafteten KMU 33,7 % aller Umsätze in Deutschland (Braun & Kay, 2021). Jedoch ist der Digitalisierungsgrad von KMU in Deutschland und auch in der EU sehr gering. Das Institut für Mittelstandsforschung Bonn ermittelte, dass im Jahr 2022 82 % der deutschen KMU eine niedrige bis sehr niedrige Digitalisierungsintensität haben.

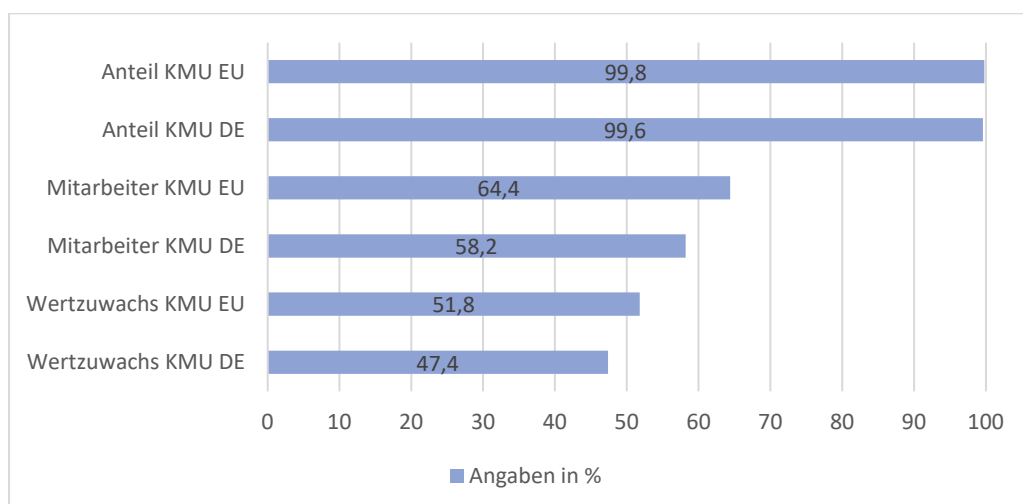


Abbildung 1: Prozentualer Anteil der KMU, Mitarbeiter in KMU sowie Wertzuwachs von KMU in Deutschland und in der EU 2021/2022 (European Commission et al., 2022)

---

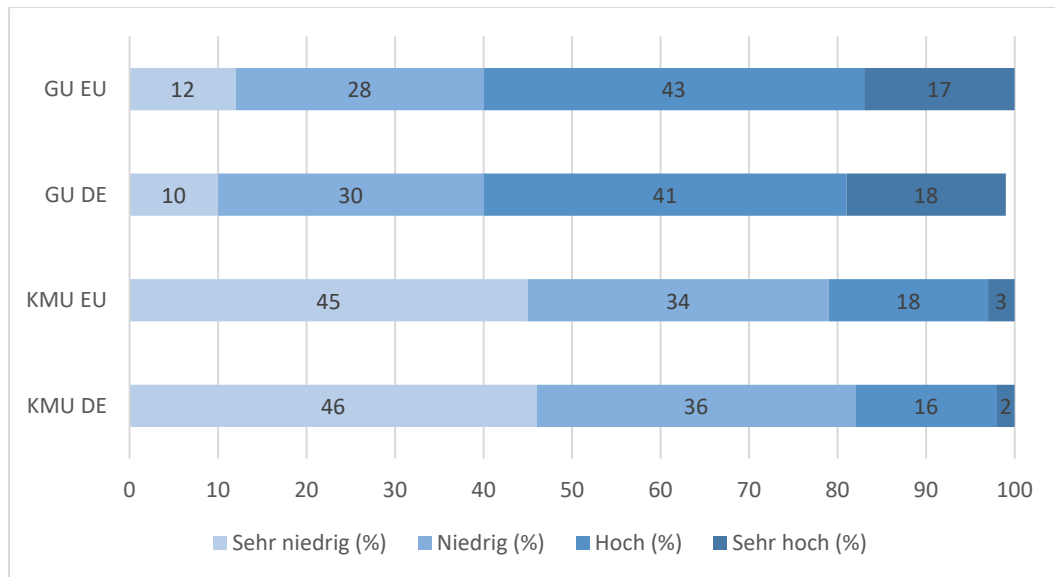


Abbildung 2: Digitalisierungsgrad von KMU und GU in 2022 (Institut für Mittelstandsforschung Bonn, 2022)

KMU müssen im Vergleich zu Großunternehmen einige Hürden bei der Einführung und Umsetzung neuer Technologien und Konzepte in Kauf nehmen, welche dazu führen, dass KMU wesentlich weniger Investitionen in den Forschungs- und Entwicklungsbereich als auch in die praktische Umsetzung investieren. Rammer et al. identifizierten die folgenden Hauptbarrieren für FuE-Aktivitäten in KMU. (Rammer et al., 2016)

- **Mindestprojektgrößen und Mindestkosten:** KMU müssen im Vergleich zu größeren Unternehmen einen höheren Anteil ihrer Gesamtressourcen in FuE-Projekte stecken, da aufgrund des technologische Aufwands Projekte nicht beliebig verkleinert werden können. Diese Ressourcen werden jedoch in anderen Unternehmensbereichen (z.B. Innovationsaktivitäten in der Prozessautomation oder im Marketing) benötigt. Weiterhin verzichten viele KMU aufgrund der hohen Mindestkosten für FuE-Projekte auf diese Aktivitäten.
- **Hohe Einstiegs- und Fixkosten in Forschung und Entwicklung:** Um FuE-Projekte umzusetzen, muss eine technische und personelle Mindestausstattung vorhanden sein, welche meist nur für ihren projektspezifischen Anwendungsbereich genutzt werden kann. Nach Beendigung der

Forschungsaktivitäten sind diese Investitionen oftmals für andere Unternehmensbereiche nicht mehr nutzbar („sunk costs“). Weiterhin haben FuE-Kosten einen hohen Fixkostenanteil, welcher sich nur bei mehreren FuE-Projekten wirtschaftlich verteilen lässt.

- **Eingeschränkte Fremdfinanzierung:** KMU-bezogene Forschung ist meist sehr spezifisch auf das jeweilige Unternehmen und deren individuellen Prozesse und Strategien zugeschnitten. Zum einen fällt es dadurch Externen schwer, die Erfolgsaussichten einzuschätzen und zum anderen ist eine Übertragbarkeit in eine breite Masse zur langfristigen wirtschaftlichen Verwertung oftmals nicht möglich. Diese Faktoren mindern die Bereitschaft externer Geldgeber, FuE-Projekte der KMU zu finanzieren.
- **Hohe Risikoexposition:** Durch die hohen Fixkosten sowie Mindestprojektgrößen können KMU nur wenige FuE-Projekte gleichzeitig verfolgen. Daher ist es ihnen im Gegensatz zu Großunternehmen nicht möglich, das Innovationsrisiko intern zu streuen. Ein Scheitern eines dieser Projekte kann bei KMU schnell zur Existenzgefährdung des Unternehmens führen, da ein erheblicher Ressourcenanteil in das FuE-Projekt floß und eventuell entstandene Defizite schwer zu kompensieren sind.
- **Forschungskooperationen:** Die Nutzung externen Wissens zur Erweiterung des eigenen Knowhows ist für KMU von besonders hoher Bedeutung. Allerdings erfordert die Bildung von Kooperationen einen hohen Investitionsaufwand und birgt zugleich auch die Gefahr des Wissensabflusses. Im Gegensatz zu Großunternehmen (GU) handelt es sich bei FuE-Projekten der KMU größtenteils um Aktivitäten, die die zentralen Kernprozesse betreffen und somit einer hohen Geheimhaltung zum Schutz des Unternehmens unterliegen.

Daher ist es von großer wirtschaftlicher Bedeutung, die Digitalisierung und den Einsatz intelligenter Datenverarbeitungsmechanismen in KMU zu unterstützen. Neben der fehlenden Expertise im IT-Bereich fällt es vielen Entscheidungsträgern in KMU

---

schwer, die Optimierungsmöglichkeiten durch künstliche Intelligenz (KI) für ihren Unternehmensbereich überhaupt zu erkennen und die Veränderungen und Erwartungen an erfolgreich eingesetzter KI zu spezifizieren. Somit erscheint die Einführung dieser Verfahren, um die benötigten Ressourcen bereitzustellen, als hoher Zeit- und Kostenfaktor. Zu diesen Faktoren gehören zuerst IT-Personal mit KI-Kompetenzen, Anschaffungskosten für eine durchgängige Digitalisierung des jeweiligen Einsatzbereiches, eventuelle Maschinenausfälle wegen durchzuführender Tests, Schulung des bestehenden Personals im Umgang mit neuen Technologien und nicht zuletzt die Einhaltung der gesetzlichen Vorgaben zum Datenschutz. Auch ist für die Unternehmen zu Beginn nicht ersichtlich, ob und in welchem Umfang Optimierungspotenziale überhaupt erkannt und wie diese dann umgesetzt werden können. Um den Digitalisierungs- und Automatisierungsprozess erfolgreich durchzuführen, bietet sich für KMU an, schrittweise Veränderungen an der IT- und Produktionsinfrastruktur vorzunehmen. Um die einzelnen Produktionsbereiche zu digitalisieren und Methoden der künstlichen Intelligenz zu nutzen, müssen also Entscheidungsträger und Mitarbeiter in diese Prozesse aktiv involviert und davon überzeugt werden. Weiterhin muss für die technische Umsetzung eine Kenntnis über die Arbeits- und Produktionsprozesse und deren Zusammenhänge bestehen. Daraus resultiert die Notwendigkeit, mit den jeweiligen Produktionsmitarbeitern in engem Kontakt zu stehen und die individuellen Arbeitsabläufe zu verstehen. Vor-Ort-Besichtigungen und eine Kommunikation über alle Ebenen dienen dabei der Verminderung kritischer Schlüsselfaktoren:

- **Nichtakzeptanz der „neuen“ Techniken:** Viele Mitarbeiter befürchten den Verlust von Arbeitsplätzen. Die Automatisierung macht bestimmte manuelle Vorgänge überflüssig. Das betrifft vorrangig einfach auszuführende Tätigkeiten, die durch Maschinen abgelöst werden könnten. Weiterhin sind mit der Einführung der Digitalisierung neue Kompetenzen und Fähigkeiten der Mitarbeiter verbunden. Daneben bestehen auch Vorbehalte bezüglich des Datenschutzes und der IT-Sicherheit.
-

- **Unvollständige Datenbasis:** Besonders in KMU wird oftmals noch mit älteren Maschinen gearbeitet. Außerdem werden bei der Umrüstung nicht komplette Maschinenparks ausgetauscht, sodass die Kommunikation zwischen den einzelnen Geräten nicht immer gegeben ist. Dadurch hat man es mit verschiedenen Kommunikationswegen und derer Kombination zwischen den Maschinen und Datenbanken zu tun. Auch in den übergeordneten Abteilungen bestehen in vielen Fällen Medienbrüche.

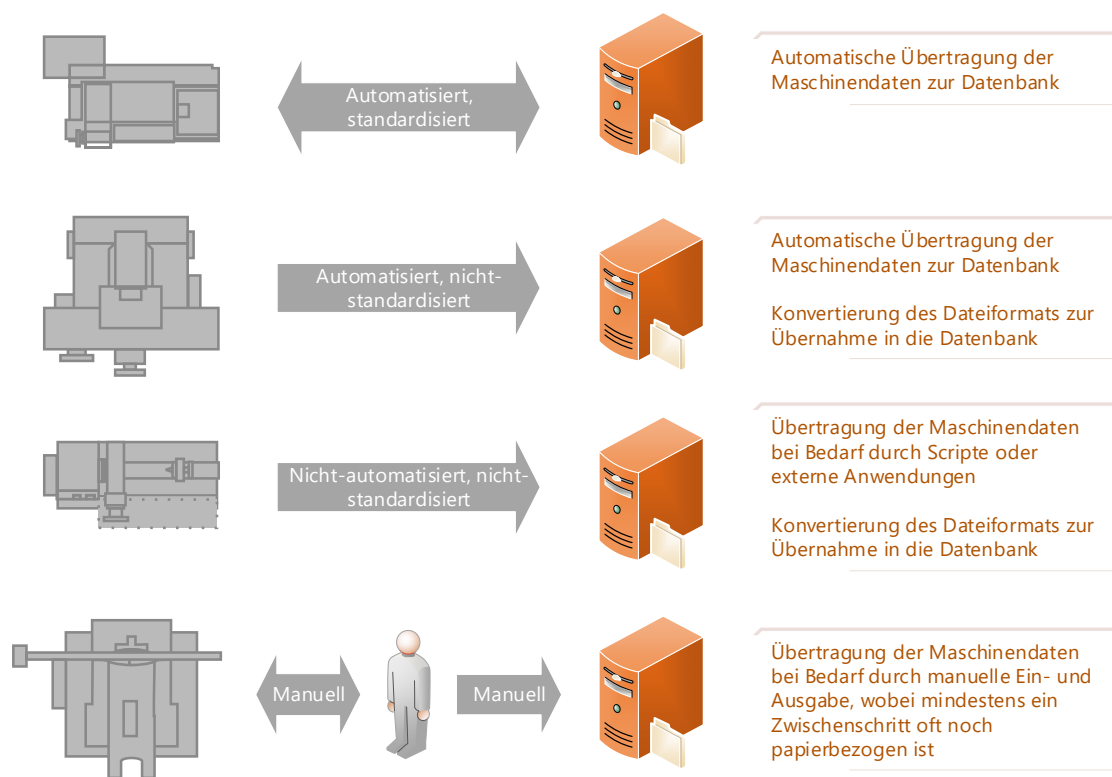


Abbildung 3: Genutzte Kommunikationswege zwischen Maschinen und Datenbanken in KMU (Eigene Darstellung)

- **Unzureichende Definition der Zielsetzung:** Die genaue Zielsetzung ist unerlässlich für Auswahl der Daten, der sinnvollen Berechnung durch die KI-Algorithmen und somit der Generierung aussagekräftiger Modelle. Nur mit einer gut vorbereiteten Datenbasis kann ein optimales Ergebnis, welches für das KMU einen deutlichen Mehrwert bringt, erreicht werden.
-

- **Unzureichende Kenntnisse der Prozesse und Arbeitsabläufe:** Für eine auf das Unternehmen optimal zugeschnittene KI ist es unerlässlich, die Arbeitsabläufe, welche die Erreichung der Zielstellung tangieren, gut zu kennen. Oftmals erscheinen den Entwicklern bestimmte Schritte nicht sinnvoll, welche sich jedoch im Laufe der Jahre für die Mitarbeiter in der Produktion bewährt haben.

KI-Anwendungen, welche sich speziell auf den Bereich des betrieblichen Umweltschutzes beziehen, findet man in verarbeitenden KMU bisher jedoch selten (Friedrich, 2021). Aufgrund der o. g. Gründe für die Schwierigkeiten der Einführung von KI und der damit verbundenen Digitalisierung konzentrieren sich produzierende KMU, wenn überhaupt, auf die ökonomischen Vorteile durch den Einsatz dieser Technologien. Sinnvoll ist daher eine Kopplung von ökonomischen mit ökologischen Vorteilen, wie sie in diesem Promotionsvorhaben durchgeführt wurde. Für die Unternehmen wird ein Kostenvorteil durch Material- und Energieeffizienz erreicht, welche gleichzeitig der Reduzierung der Umweltbelastung durch Senkung der Treibhausgas-Emissionen sowie der Ressourcenschonung dienen.

Für den Sektor des produzierenden Gewerbes bieten insbesondere Verfahren der KI ein hohes Nutzenpotenzial in den Bereichen des Ressourcenmanagements und der Prozessoptimierung sowie der vorausschauenden Wartung. Als weitere Bereiche identifizierte die Universität des Saarlandes die KI-Anwendungsfelder Assistenzsysteme, Wissensmanagement, Qualitätskontrolle, Automatisierung, Robotik, Sensorik, Sprachsteuerung sowie autonomes Fahren und Fliegen (Kaul et al., 2019).

Mit der Nutzung der Hardwarekomponenten, die mit der Digitalisierung einhergeht, muss jedoch auch in Betracht gezogen werden, dass die dadurch gewonnenen Energie- und Materialreduktionen an anderer Stelle ansteigen. Automatisierte Prozesse benötigen ein hohes Maß an IKT-Komponenten, deren Gewinnung und Herstellung die Umwelt stark belasten. Auch wenn die genutzten Endgeräte immer energieeffizienter werden, sind sie jedoch weit häufiger in Gebrauch. Weiterhin erfordert die

---

Datenspeicherung und -verarbeitung in der Cloud einen immensen Energieaufwand. 2020 betrug der jährliche Primärenergieverbrauch weltweit 595,15 EJ (Bundesministerium für Wirtschaft und Klimaschutz, 2022). Davon entfallen ca. 4-6 % auf IKT-Komponenten (UK Parliamentary Office of Science and Technology, 2022), was einem Energieverbrauch von ca. 23,8 – 35,7 EJ entspricht. Die in der Literatur enthaltenen Daten zum Energieverbrauch beinhalten jedoch nicht die Gewinnung, Herstellung und Entsorgung von IKT-Geräten. Diese Daten können aufgrund der komplexen Produktions- und Entsorgungsprozesse und des variierenden Anteils an Elementen nur grob geschätzt werden. Die ausführlichste Darstellung zu dem Stoff- und Energiebedarf beim Abbau von Seltenerdmetallen, welche die Grundlagen der IKT-Komponenten bilden, gaben Peiró und Méndez (Talens Peiró & Villalba Méndez, 2013). Dabei wurden die Energie- und Materialverbräuche über die verschiedenen Phasen des Abbaus, der Aufbereitung und der Trennung untersucht. Die Raffination wurde nicht betrachtet, da diese sich je nach späterem Einsatzzweck und Art des Elements unterscheidet.

	Recovery rate REM (%)	Material input (tonnes)	Energy input (GJ)
Mineral processing			
Mining			
Bastnäsite Bayan Obo	50	60.2 mined ore	6
Bastnäsite Mountain Pass	90	17.4 mined ore	1.7
Monazite/xenotime	75	160.2 mined ore	6.4
Beneficiation			
Extraction 1: Bayan Obo mineral	72	5.97 bastnäsite 4.41 sulfuric acid 12.32 sodium chloride 1.64 sodium hydroxide 1.17 hydrochloric acid 1.90 water	6.06–9.29
Extraction 2: Bastnäsite by Kruesi and Duker	92	1.95 bastnäsite 1.35 hydrochloric acid 0.33 sodium hydroxide	0.03–0.04
Extraction 3: Bastnäsite by Goldschmidt process	97	2.56 bastnäsite 2.44 chlorine	4.26–6.32
Extraction 4: Baotou concentrates	91	2.73 bastnäsite 1.58 chlorine	6.80
Extraction 5: Monazite by Rhône-Poulenc	90	2.21 monazite 1.23 sodium hydroxide 1.94 nitric acid	0.06
Extraction 6: Xenotime	80–90	2.92 xenotime 7.58 sulfuric acid 1.83 oxalic acid	0.13–0.15
Separation			
Solvent extraction	90–95	7.02–7.40 TBP	15.60–22.70
Reduction			
Metallothermic reduction		–	0.33*
Electrolysis		–	38–48

\* Theoretical estimate for Cerium.

Abbildung 4: Material- und Energieverbrauch für die Produktion einer Tonne seltener Erden (Talens Peiró & Villalba Méndez, 2013)

Da Seltenerdmetalle in der Natur vergesellschaftet und mit verschiedenen Konzentrationen vorkommen, unterscheiden sich die Material- und Energiemengen für die Gewinnung des jeweiligen Elements. Je nach der Form ihrer Vergesellschaftung und geografischer Lage der Mine werden für die Produktion einer Tonne Seltenerdmetalle ca. 17 – 160 Tonnen Erz benötigt. Allein für die Schmelzflusselektrolyse am Beispiel der Abbildung 4 zur Nutzung des Metalls Cer als Werkstoff werden 38-48 GJ an Energie benötigt. Zur Verdeutlichung des hohen Ressourceneinsatzes entspricht dies in etwa dem durchschnittlichen Jahresverbrauch von drei 4-Personen-Haushalten.

## **2. Theoretische Grundlagen von künstlicher Intelligenz**

Das folgende Kapitel beschreibt die theoretischen Grundlagen von KI. Die Grundlagen von Seltenerdmetallen sind in der beigefügten Veröffentlichung ausführlich dargestellt, daher kann an dieser Stelle darauf verzichtet werden.

Der Begriff „künstliche Intelligenz“ wurde bisher – und wird teilweise immer noch – verwendet, um Maschinen zu beschreiben, die „menschliche“ kognitive Fähigkeiten nachahmen, wie z. B. „Lernen“ und „Problemlösen“ und bedeutet die Abbildung von „intelligentem Verhalten“ auf die IT. Jedoch hängt die Fähigkeit des Menschen, Probleme zu lösen, Entscheidungen zu treffen, langfristig zu denken und Konsequenzen zu erkennen von vielen biologischen und soziologischen Faktoren ab, so dass es bisher keine einheitliche Definition und Messmethode für „Intelligenz“ gibt. In der Biologie, Psychologie und Neurologie gilt daher „Intelligenz“ als mentale Eigenschaft, die in der Fähigkeit besteht, aus Erfahrung zu lernen, Probleme zu lösen und Wissen einzusetzen, um sich an neue Situationen anzupassen (Myers, 2014). Im Sinne der künstlichen Intelligenz wird diese daher vermehrt als Rationalität und rationales Handeln beschrieben (Russell & Norvig, 2021). Computerprogramme werden für die Lösung eines bestimmten Problems entworfen, welches sie unter

---

Nutzung der Hardware lösen. Das Gehirn jedoch besteht aus einer Vielzahl hochspezialisierten Arealen, die miteinander stark verknüpft sind. Neben der Gedächtnisleistung (Aufnahme, Weiterleitung und Verarbeitung, Speicherung von Informationen) ist das Gehirn auch für die Steuerung der vegetativen Funktionen (Atemfrequenz, Herzschlag, Blutdruck, Thermoregulation, Stoffwechsel) zuständig und bildet so ein evolutionär auf optimale Zusammenarbeit ausgelegtes super-effizientes System. Für die Komplexität und Verzahnung der verschiedenen Funktionsbereiche mit ihren chemischen und elektrischen Prozessen, die dynamischen synaptischen Verbindungen zwischen den Neuronen sowie die Neuroplastizität und Neurogenese ist es bisher auf medizintechnischer und neurowissenschaftlicher Ebene nicht gelungen, eine „kleinste funktionellen Einheit“ des Gehirns zu identifizieren (Kurreck et al., 2022). Dies würde jedoch die Grundlage für die Nachbildung menschlichen Verhaltens und deren Übertragung in die Informatik sein. Auch unter dem Aspekt der Effizienz ist das Gehirn heutigen Computern überlegen. Bei einer Anzahl von ca. 86 Millionen Nervenzellen (Herculano-Houzel, 2009), welche pro Neuron mehrere tausend synaptische Verbindungen mit anderen Neuronen eingehen kann, passt die Gesamtlänge von  $10^8$  Leitungsbahnen in ein Volumen von ca. 1,5 kg (Churchland & Sejnowski, 2016) und verbraucht durchschnittlich gerade mal 20 W. Das Gehirn benötigt  $10^{-3}$  s für eine elementare Berechnung, kann jedoch diese Leistung nicht durch eine hohe Geschwindigkeit bei der Durchführung der einzelnen Rechenschritte, sondern durch die massiv-parallele Konnektivität erreichen. Diese Eigenschaften des Gehirns begründen die Forschungsaktivitäten im Bereich der KI sowie der Entwicklung neuromorpher Computerarchitekturen (Baek et al., 2020) (Müller et al., 2022). Klammert man die psychologischen Aspekte wie Emotionen und Bewusstsein aus sowie das hoch-automatisierte Zusammenspiel der einzelnen Funktionen des menschlichen Gehirns aus, bietet KI wichtige technologische Eigenschaften in Ergänzung zum biologischen Vorbild.

- **Gedächtnis:** Das gesamte erlernte Wissen des Menschen wird nicht komplett abrufbar gespeichert. Informationen werden im Langzeitgedächtnis nicht als
-

einzelner Datensatz sondern in Abhängigkeit von ihrer subjektiven Bedeutung (Berlit, 2020) über verschiedene Ebenen (prozedural, deklarativ/episodisch, deklarativ/semantisch) gespeichert. Die Häufigkeit der Nutzung von Gedächtnis-Informationen mit Bezug zum thematischen Kontext sowie die Priorisierung nach Relevanz der sensorischen Wahrnehmungen entscheiden über die Dauer der Verfügbarkeit und auch die Genauigkeit der gespeicherten Daten. Das Wissen des Menschen muss daher für eine langfristige und korrekte Verwendung extern abgelegt werden.

- **Weitergabe von Wissen:** Auch wenn eine Methodik bekannt ist, muss jedes Individuum diese neu erlernen und benötigt dafür Hilfsmittel wie Anleitungen oder Lehrer. Beispielsweise erfordert das Erlernen der Integralrechnung eine bestimmte Zeit der Übung sowie Lehrmaterial über den Berechnungsvorgang. Der Computer ist dagegen in der Lage einen programmierten Algorithmus an andere Rechner zum sofortigen Einsatz weiterzugeben.
- **Anwendung von Wissen:** Neben der Weitergabe von Wissen ist ein Computer bei Berechnungen dem Gehirn bezüglich Geschwindigkeit überlegen. Allerdings kann induktives Denken – die mathematische Beweisführung, die den Theoremen zugrunde liegen und die letztendlich die Rechenregeln bilden, noch nicht von Maschinen geleistet werden.
- **Objektivität:** Menschen sind in ihrer Allgemeinheit nicht objektiv. Da, wie bereits beschrieben, Informationen im deklarativen Gedächtnis mit ihrer subjektiven Bedeutung gespeichert werden, sind diese nicht wertungsfrei. Weiterhin kann sich erinnertes Wissen aufgrund der Neuroplastizität (Fähigkeit des Gehirns, sich auf Grundlage von Erfahrungen umzustrukturieren) verändern (Eagleman, 2021). Menschen unterliegen kognitiven Verzerrungen. Diese Prozesse der beeinflussten Wahrnehmung und Urteilsfähigkeit laufen in der Regel unterbewusst ab. Ein Computer speichert Informationen zwar in verschiedenen Detaillierungsgraden, jedoch stets objektiv.

Die Werkzeuge der KI sind die Algorithmen des maschinellen Lernens. Die existierenden Algorithmen sind zweckbezogen, d.h. dass bei der Auswahl des Algorithmus die Problemstellung ausschlaggebend ist. Die Auswahl erfolgt dann anhand der Einteilung der Algorithmen in Lernarten (überwacht, unüberwacht, semi-überwacht und bestärkend) und Lernaufgaben (Regression, Klassifikation, Cluster- und Assoziationsanalyse, Dimensionsreduktion, wert- und strategiebasierte Entscheidungsfindung durch Belohnung).

Beim überwachten Lernen sind die gewünschten Ausgabedaten bekannt, d.h. zu jedem Trainingsziel liegen die richtigen Ergebnisse vor, während beim unüberwachten Lernen Muster und auch Unterschiede in den oftmals unstrukturierten Daten erkannt werden. Das semi-überwachte Lernen kombiniert das überwachte und unüberwachte Verfahren und wird vorwiegend bei Datenbeständen eingesetzt, die teilstrukturiert vorliegen. Beim bestärkenden Lernen agiert die Maschine mit ihrer Umwelt. Dabei lernt der Algorithmus durch „Belohnung“ oder „Bestrafung“ in Form einer Nutzenfunktion. Ziel dieser sogenannten Agenten ist die Maximierung der Nutzenfunktion. Die Modelle sind die Trainingsergebnisse der Algorithmen, beispielsweise Regressionsgeraden, Entscheidungsbäume, künstliche neuronale Netze, Hyperebenen. Die folgende Tabelle gibt einen Überblick über die Lernarten, die Lernaufgaben und die am häufigsten genutzten Algorithmen mit einer kurzen Beschreibung.

Tabelle 1: Überblick über ML-Algorithmen

Lernart	Lernaufgabe	Algorithmen	Beschreibung
<b>Überwacht</b>	Regression	Lineare Regression	Beziehung zwischen einer abhängigen Zielvariablen und einer oder mehrerer unabhängiger Variablen
		Rekurrentes Neuronales Netz	KNN mit rückgekoppelten Neuronen und gleichen Gewichtungen in den Schichten des Netzes, welches sequenzielle Daten oder Zeitreihen verarbeitet
		Entscheidungsbäume und Random Forest	Entscheidungsbäume: Darstellung aller möglichen Ergebnisse als Baumdiagramm Random Forest: Darstellung aller möglichen Ergebnisse unkorrelierter Entscheidungsbäume zur Klassifizierung durch Kombination der einzelnen Ergebnisse
	Klassifikation	Logistische Regression	Beziehung zwischen einer abhängigen binären Zielvariablen und einer oder mehrerer unabhängiger Variablen zur Vorhersage eines kategorialen Ergebnisses
		Convolutional Neural Networks	Speziell für die Bildverarbeitung und Objekterkennung entwickeltes dreidimensionales KNN, welches in einem Bild verschiedenen Objekten bestimmte Gewichtungen zuweist

Lernart	Lernaufgabe	Algorithmen	Beschreibung
		Support Vector Machines	Zuordnung von Objekten zu bestimmten Klassen und Teilung von Daten durch Hyperebenen, die den maximalen Abstand zwischen den Datenpunkten der Klassen aufweisen
		Naive Bayes	Berechnung von Wahrscheinlichkeiten der Klassen unter der Annahme von bedingt unabhängigen Variablen
		Gradient Boost	Kombination schwacher Modelle, um Bias-Fehler zu minimieren
Unüberwacht	Clusteranalyse	K-Means	Gruppieren von Daten und Auffinden der Zentren in Datenclustern, deren Anzahl vorher festgelegt sein muss
		DBSCAN	Dichtebasiertes Clustering von Daten mit Rauschen
		Hierarchische Clusteranalyse	Gruppierung von Daten in hierarchischen Klassen und schrittweise Agglomeration der Klassen in ein Dendrogramm
	Dimensionsreduktion	Principal Component Analysis	Strukturierung großer Datensätze durch Reduzierung der Dimensionalität unter bestmöglicher Wahrung der statistischen Informationen
	Verschiedene	GAN	Erzeugung von Daten durch Kombination von zwei sich gegenseitig verbessernden KNN, wobei eines die Daten erzeugt und das andere diese als

Lernart	Lernaufgabe	Algorithmen	Beschreibung
			„echt“ oder „künstlich erzeugt“ klassifiziert
		Hidden-Markov-Modelle	Bestimmung der wahrscheinlichsten Folge aus nichtbeobachtbaren Zuständen durch Faktorisierung
		Isolation Forest	Identifikation von Ausreißern in einem mehrdimensionalen Raum auf Basis von Entscheidungsbäumen
		Apriori-Algorithmus	Auffinden von Assoziationsregeln in einer Transaktionsmenge durch Suche nach häufigen Mengen
<b>Bestärkend</b>	Wertbasiert	Q-Learning	Erlernen des optimalen Aktionswerts in einem bestimmten Zustand
		Monte-Carlo-Algorithmus	Generierung von Zufallsstichproben zur Schätzung eines Zustandswertes
	Strategiebasiert	REINFORCE	Schätzung der Gewichte für eine optimalen Strategie durch Gradientenanstieg
		Hill-Climbing	Auffinden der optimalen Strategie, indem die bestehenden Gewichtungen im Netzwerk iterativ verbessert werden

Anstelle der Lernarten „überwacht“, „unüberwacht“ und „bestärkend“ wird in der theoretischen Informatik häufig in „parametrisiert“ und „nicht-parametrisiert“ unterschieden. Das bezieht sich nicht auf den Algorithmus, sondern auf sein Ergebnis – das Modell. Zusammenfassend kann gesagt werden, dass parametrisierte Lernar-

ten als Modell eine Funktion mit einer bestimmten Anzahl an Parametern ausgeben, welche vor dem Training festgelegt wurde. Nicht-parametrisierte Modelle hingegen entwickeln erst im Laufe des Trainings ihre Parameteranzahl. Beispielsweise gehören künstliche neuronale Netze zu den parametrisierten Verfahren, die eine festgelegte Anzahl einstellbarer Parameter haben, während Entscheidungsbäume jedoch während des Trainings neue Ausprägungen in Form von Ästen bilden.

Künstliche Intelligenz kann sehr große Mengen unstrukturierter Daten in hoher Geschwindigkeit analysieren, kategorisieren und klassifizieren, um daraus Muster zu erkennen. Die KI „versteht“ jedoch nicht, warum sie das tut. Sie kann (noch) keine abstrakten Rückschlüsse auf Probleme ziehen. KI ist nicht kreativ, innovativ und strategisch, um eigene Lösungen für ein neues Problem zu finden.

### **3. Zielsetzung und Fragestellung**

Das Ziel der vorliegenden Dissertation besteht in der Entwicklung von KI-Verfahren zum Einsatz in produzierenden KMU zur Einsparung von Energie und Abfall für die gesamte Fertigung. Die Steigerung der Material- und Energieeffizienz führt neben einer Verminderung von Umweltbelastungen und -schädigungen zu einer Senkung der Produktionskosten in Unternehmen, was wiederum zu einer Steigerung der Wettbewerbsfähigkeit führt. Die praktischen Forschungsarbeiten wurden im DBU-geförderten Projekt „Nova - Entwicklung einer neuen Methode zur Ressourceneinsparung durch prozessorientiertes, digitales Stoffstrommanagement in produzierenden mittelständischen Unternehmen“ (Förderkennzeichen: 24589/01, Deutsche Bundesstiftung Umwelt) in Kooperation mit der Novapax Kunststofftechnik Steiner GmbH & Co. KG entwickelt. Novapax ist in der Fertigung von Spritzgussteilen/Präzisionskunststoffteilen überwiegend für die Bereiche Automobilindustrie, aber auch für die Branchen Bau, Elektronik, Medizin und Sanitär tätig. Exemplarisch an diesem konkreten Anwendungsfall wird eine adaptierbare Lösung für die Ressourcenoptimierung von Material und Energie durch das maschinelle Lernverfahren Random

---

Forest (RF) sowie die Entwicklung eines künstlichen neuronalen Netztes (KNN) erarbeitet.

Dabei werden die folgenden Forschungsfragen adressiert:

- Wie können durch Methoden des maschinellen Lernens Zusammenhänge zwischen den Parametereinstellungen der Maschinen, dem Energieverbrauch sowie der Wahrscheinlichkeit von fehlerhaft produzierten Kunststoffteilen hergestellt werden und welche Parameteränderungen senken den Energieverbrauch und reduzieren die Wahrscheinlichkeit von Fehlproduktionen?

Letztendlich soll das RF-Modell Aussagen darüber treffen können, dass Maschine  $x$  unter Änderung der Parameter  $y_1, y_2, \dots, y_n$  den Energieverbrauch pro produzierten Teil um  $z$  kWh reduzieren kann.

Auf Basis des RF-Modells wird dann ein KNN entwickelt, um die Genauigkeit dieser Aussagen zu erhöhen. Die Entwicklung des KNN adressiert die folgende Forschungsfrage:

- Wie können neuronale Netze verwendet werden, um ideale Maschineneinstellungen zu finden, um den Energieverbrauch zu reduzieren und die Qualität zu verbessern?

Für den praktischen Einsatz soll das KNN Aussagen zu folgenden Fragestellungen treffen:

- Wie viel Energie könnte eingespart werden, wenn die vom KNN vorgeschlagenen optimalen Maschinenparametereinstellungen verwendet werden würden?
  - Wie weit kann die Qualität unter Betrachtung der Reduzierung von Kunststoffausschuss verbessert werden?
-

Die Aussagen dieser beiden KI-Verfahren sollen außerdem für den Menschen interpretierbar sein, da viele KI-Modelle, insbesondere jedoch KNN ein Black-Box-Verhalten aufweisen.

Ganzheitliche Digitalisierung und die dadurch zu verarbeitenden Daten mit Verfahren der KI sind entscheidende Schritte für eine ressourcenschonende Produktion. Dazu zählen in erster Linie die Verbesserung der Effizienz und Performance sowie die Optimierung der Störungsanfälligkeit von Produktions- und Geschäftsprozessen durch Automatisierung als auch die konsistente Verfügbarkeit von Informationen in Zusammenhang mit schnellem Wissenstransfer. Allerdings birgt die Digitalisierung auch umweltbezogene Nachteile. Dies spiegelt sich vor allem im steigenden Rohstoffbedarf für elektronische Komponenten und dessen kostengünstige Beschaffung überwiegend in Ländern mit geringen Umwelt- und Sozialstandards wider. Für eine kritische Betrachtung werden die Umweltauswirkungen der technologischen Komponenten von der Gewinnung bis zur Entsorgung mit Fokus auf Seltenerdmetallen untersucht. Dabei soll der produktionsseitige Rebound-Effekt (Jevons, 1865) in Zeiten der Digitalisierung in Bezug auf die Nutzung von Seltenerdmetallen im Vordergrund stehen.

#### **4. Forschungsdesign**

Das übergeordnete Ziel der Dissertation ist die Prozessoptimierung durch Identifikation von Parametereinstellungen an den Produktionsmaschinen zur Energiereduktion und Abfallminimierung. Nach der Implementierung einer grundlegenden homogenen Datenspeicherung der Maschinendaten wurden für die Umsetzung im ersten Schritt ein Random Forest-Modell und darauf aufbauend ein KNN entwickelt. Das Forschungsdesign orientiert sich an den 7 Leitgedanken des Design Science Research (DSR) nach Hevner et. al. und folgt deren Information Systems Research Framework. (Hevner et al., 2004)

---




Abbildung 5: Information Systems Research Framework (Hevner et al., 2004)

Design Science Research ist ein gestaltungsorientierter Ansatz, der aus der Wirtschaftsinformatik stammt und die Entwicklung von Informationssystemen beschreibt (Wilde & Hess, 2006). Ziel ist die Erstellung eines konkreten Artefakts. Hevner et. al. bauen auf den Arbeiten von Herbert A. Simon (Simon, 1996) und Silver, Markus und Beath (Silver et al., 1995) auf.

Im Zuge des Design Methods Movement in den 60er Jahren des 20. Jh. beschrieb Simon die Designtheorie anhand der „Wissenschaften des Künstlichen“ in seinem Werk „The Sciences of the Artificial“, wobei Nachbildungen der Natur in den Wissenschaften als Artefakte gelten. Diese Artefakte können sich aufgrund ihrer Funktionalität und ihrer Umgebung anpassen. Durch logisches Verknüpfen von Beziehungen können innerhalb eines Prozesses neue Erkenntnisse gewonnen werden. Auf Basis mathematischer Berechnungen können Computer diese Prozesse optimieren und automatisieren. Simon definierte Design Science als „wie Dinge sein könnten“ und die Naturwissenschaft als „wie Dinge sind“. Mit Allen Newell und Cliff Shaw entwickelte Simon den Logical Theorist, der auf der Dartmouth Conference, dem ersten Workshop für künstliche Intelligenz unter der Organisation von John McCarthy, vorgestellt wurde. Der Logical Theorist ist ein Computerprogramm, welches eine Vielzahl der Theoreme der Principia Mathematica von Whitehead and

---

Russell (Whitehead & Russell, 1925-1927) beweisen konnte und als erstes KI-Programm gilt, welches in der Lage ist, komplexe Probleme zu lösen und so menschliches Denken zu imitieren. 1975 wurde Simon mit seinem Kollegen Newell mit dem ACM Turing Award ausgezeichnet. (Association for Computing Machinery, 1975) Aufgrund seiner organisationstheoretischen Arbeiten zu Entscheidungsprozessen erhielt er 1978 den Alfred-Nobel-Gedächtnispreis für Wirtschaftswissenschaften.

Silver et. al. beschrieben erstmals ein IT-Interaktionsmodell aus Prozessperspektive über die verschiedenen Stadien des Implementierungsprozesses. Das Modell integriert 4 miteinander verbundene Phasen – die Organisation mit ihren Geschäftsprozessen, das zu entwickelnde Informationssystem, die Einführung des Systems und deren Auswirkungen. Durch die Integration von Systemeffekten ist das Modell mit dem Konzept der Entscheidungsunterstützung verknüpft.

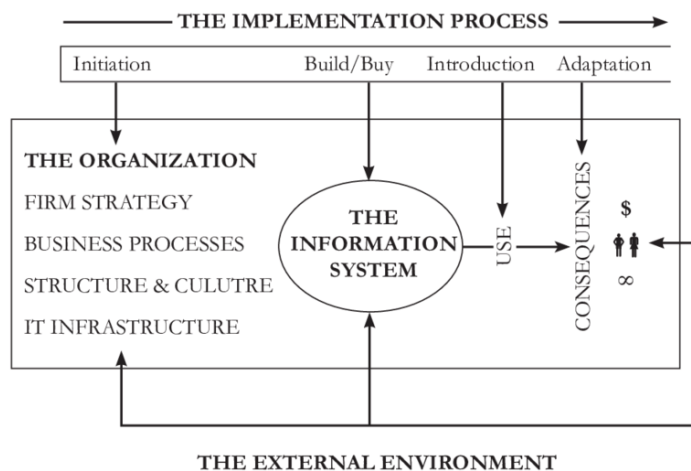


Abbildung 6: IT Interaction Modell (Silver et al., 1995)

Neben der Methodik nach Hevner (Hevner et al., 2004) haben sich weitere DSR-Modelle für die Entwicklung von IT-Lösungen etabliert (Peffer et al., 2007). Allen liegt das gemeinsame Ziel einer strukturierten, transparenten Forschung und Entwicklung zu Grunde. Die Entscheidung für das Modell nach Hevner et al. als Forschungsdesign für diese Dissertation begründet sich im Praxisbezug als Ausgangspunkt mit der Integration der Unternehmensstruktur und -prozesse sowie des iterativen Zusammenspiels von Praxis, Entwicklung und Forschung. Das methodische

---

Vorgehen der Forschungsarbeiten der vorliegenden Dissertation lässt sich wie folgt in die sieben Design Science Research Guidelines nach Hevner et. al. einordnen.

- 1. Artefakt-Design:** Die zu entwickelnden Artefakte sind ein RF-Modell und ein darauf aufbauendes KNN zum Auffinden der optimalen Parametereinstellungen an den Produktionsmaschinen, um den Energieverbrauch unter Einhaltung der Qualitätskriterien sowie den Abfall zu verringern. Um dieses Artefakt zu generieren, ist es notwendig, als Ausgangsbasis eine konsolidierte Datenbasis zu schaffen. Im Rahmen der vorliegenden Dissertation wurden 4 Maschinen mit 34 Merkmalen und insgesamt 777.458 Daten über einen Erfassungszeitraum von 4 Monaten zugrunde gelegt. Bei der Betrachtung von Maschinen unterschiedlicher Bauweisen kommt es in den meisten Fällen zu Inkonsistenzen der Datenbasis, da einige Merkmale nicht erhoben werden. Gründe dafür liegen in der Umstellung der Produktionsweise der Maschine aber auch darin, dass gewisse Bauteile der Merkmalspalten in einigen Maschinen schlicht nicht existieren. Diese fehlenden Daten müssen für ihre Nutzung im KI-Modell bereinigt werden. Weiterhin ist es nötig, die Attribute der Daten zu standardisieren und zu normalisieren. Häufig befinden sich in den Datenbanken Daten ohne Informationsgewinn für die Lösung der definierten Problemstellung. Diese Merkmale sollten für eine effiziente Berechnung des Modells entfernt werden.
- 2. Problemrelevanz:** Die Relevanz ergibt sich aus dem Unternehmensziel des effizienteren Wirtschaftens, um positive ökonomische Effekte zu erzielen als auch aus dem ökologischen Kontext, einen effizienteren Umgang mit Stoffen und Energie zu erreichen. Zu Beginn der eigentlichen Entwicklungsarbeiten ist eine übersichtliche, strukturierte Planung vorgenommen worden. Beginnend wurde untersucht, ob der Einsatz von KI für die Zielstellung überhaupt in einem angemessenen Aufwand-Nutzen-Verhältnis steht. Daher wurde der folgende Ablauf der Einführung von KI identifiziert und möglichst allgemein gehalten, damit er auf andere Problemdefinitionen von KMU adaptierbar ist.




Abbildung 7: Konzeptioneller Ablauf der Einführung von KI in KMU (Eigene Darstellung)

- 3. Bewertung des Designs:** Die Artefakte werden unter dem Kriterium entwickelt, die eingesetzten Technologien so einfach wie möglich zu entwickeln. So wird sichergestellt, dass sie auf andere Szenarien leichter adaptierbar sind und die Fehleranfälligkeit reduziert wird. Die Ergebnisse des RF-Modells sowie insbesondere des KNN werden interpretierbar gemacht. Somit können die Ergebnisse der KI-Algorithmen auf Stimmigkeit geprüft werden. Das ist besonders für den Produktionsmitarbeiter eine notwendige Anforderung an das System, da nur dieser letztendlich beurteilen kann, ob vorgeschlagene Parameteränderungen überhaupt möglich oder für den gesamten Prozessschritt sinnvoll sind. Letztendlich werden die Artefakte bezüglich ihrer praktischen Anwendung geprüft. Besonderes Augenmerk wird dabei auf die Wiederholbarkeit der Ergebnisse bei sich ändernder Datenlage sowie der Stabilität ihrer Funktionalität gelegt. Die Szenarien, bestehend aus 4 Maschinen, werden dafür in mehreren Durchläufen auf Genauigkeit ihrer Berechnungen und der damit verbundenen Leistungsfähigkeit überprüft.
  - 4. Beitrag zur Forschung:** Die Forschungsergebnisse werden in peer-review-Magazinen dem interessierten Fachpublikum zur Verfügung gestellt. Weiterhin fließen die Arbeiten in die universitäre Ausbildung ein. Weiterhin sollen die Arbeiten einen direkten Beitrag für die produzierenden KMU leisten. Daher wird diese Dissertation in deutscher Sprache verfasst, um die Ergebnisse einfacher in die regionalen KMU zu streuen. Für die direkt an der Produktion Beteiligten soll die Interpretierbarkeit des Systems sowie die technische Adaptierbarkeit die Einführung von KI-Verfahren in KMU erleichtern. Diese Aspekte erleichtern einerseits das Vertrauen in die KI-Methoden und schaffen Transparenz der Prognosen der Black-Box der Algorithmen.
  - 5. Forschungsstrenge:** Die Entwicklung der Algorithmen erfolgt unter Zuhilfenahme etablierter Architekturen in der Programmiersprache Python. Diese zeichnet sich durch ihre sehr gute Portabilität sowie einer hohen Anzahl an Bibliotheken für KI-Programmierung und Datenauswertung aus. Als
-

Entwicklungsumgebungen für das RF-Modell werden PyCharm und Jupyter Notebook eingesetzt. Die PyCharm-IDE ist eine der erfolgreichsten Python-Umgebungen und bietet alle notwendigen Funktionen für professionelle Programmierung. Jupyter Notebook wird am Anfang der Entwicklung für die Anpassungen und die Tests der einzelnen Parameter verwendet, PyCharm kommt anschließend zum Einsatz, um gut strukturierten Code zu erstellen sowie Anpassungen der eingebundenen Bibliotheken vorzunehmen. Für die Basis der Artefakte – eine homogene Datenhaltung – werden die Maschinendaten über verschiedene Protokolle in einer SQL-Datenbank gespeichert und mittels eines dafür generierten Scriptes periodisch per VPN vom Unternehmen zum Entwicklungsrechner an der HTW Berlin gesendet. LIME (Local Interpretable Model-agnostic Explanations) gehört zu den AIX-Methoden (Explainable AI) und ist ein Framework, welches die Vorhersage der Klassifikatoren erklärt und somit der Erklärung der Black Box-Lernprozesse der Modelle ermöglicht, um die Ergebnisse nachzuvollziehen und auf Sinnhaftigkeit zu überprüfen.

- 6. Design als Optimierungsprozess:** Um die gewünschten Ziele und somit ein funktionsfähiges Artefakt zu erreichen, sind mehrere Trainings-/Test- und Optimierungsdurchläufe sowohl beim RF-Modell als auch beim KNN nötig. Die Prozesse bei KI-Verfahren sind in Abbildung 8 und Abbildung 9 grafisch dargestellt.

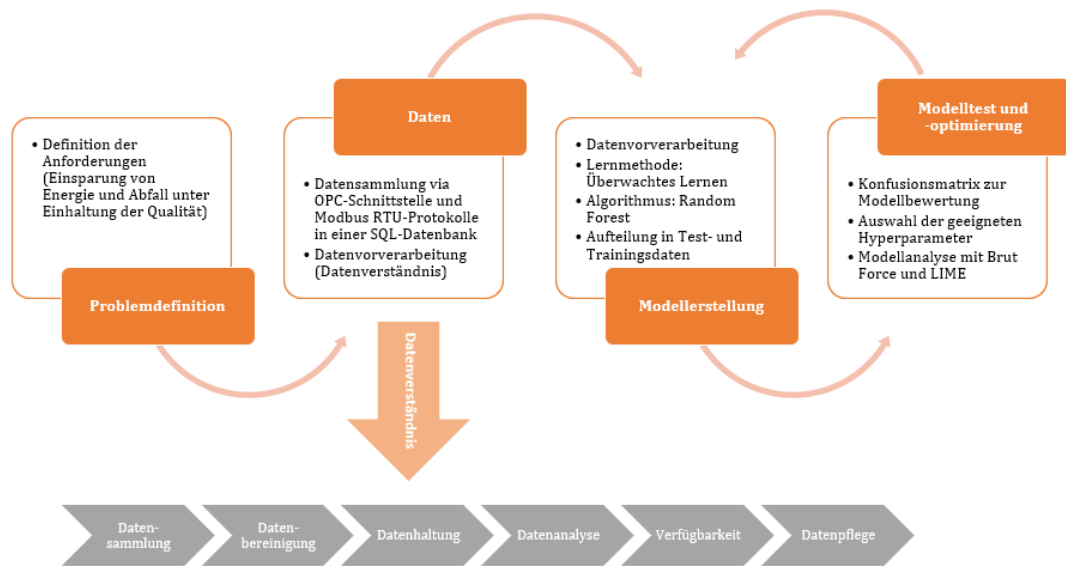


Abbildung 8: Prozess des RF-Modells (Eigene Darstellung)




Abbildung 9: Prozess des KNN (Eigene Darstellung)

**7. Kommunikation der Forschung:** Die Forschungsmethoden und -ergebnisse wurden auf mehreren Konferenzen (siehe Anhang A) sowie in verschiedenen Fachjournalen publiziert. Weiterhin fließen sie in die Lehrausbildung von Studenten ein und bilden eine Grundlage für die Durchführung weiterer Forschungsprojekte zur Digitalisierung und der Einführung von KI in KMU.

Auf Basis der Zuordnung der Forschungsarbeiten zu den sieben Leitgedanken gliedert sich die Dissertation wie in Abbildung 10 visualisiert in das Information Systems Research Framework nach Hevner et al. (Hevner et al., 2004) und fast die Schlüsselfaktoren komprimiert zusammen.

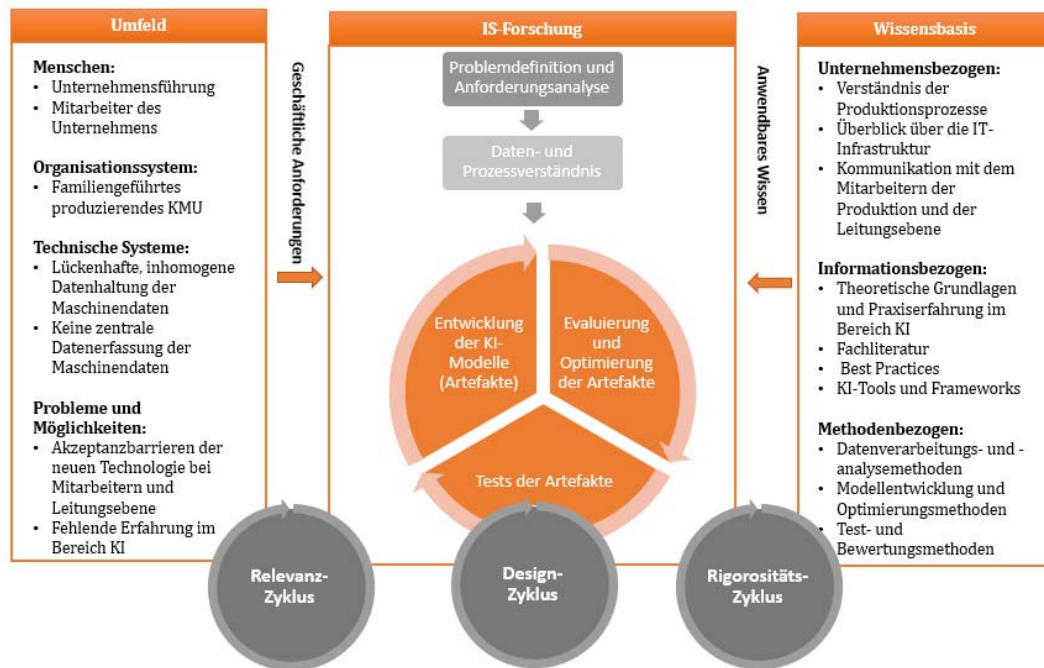


Abbildung 10: DSR-Prozess der Dissertation im IS Research Framework nach Hevner (Hevner et al., 2004)

In seinen weiterführenden Arbeiten stellte Hevner explizit die drei DSR-Zyklen (Hevner, 2007) in den Fokus. Dies soll die Motivation des DSR in der Hinsicht verdeutlichen, dass Technologieentwicklung (DSR-Zyklus) auf Basis fundierter wissenschaftlicher Erkenntnisse (Rigorositäts-Zyklus) das adressierte Umfeld (Relevanz-Zyklus) verbessern soll (Simon, 1996). Im Relevanz-Zyklus gehen die Forschungsfragestellungen sowie die Unternehmensanforderungen in den Design-Zyklus über. Dort werden die technischen Anforderungen des Artefakts, sowie dessen Entwicklung auf Basis der wissenschaftlichen Informationen und Methoden angesiedelt. Das Design des Artefakts geht mit einer fortlaufenden Abstimmung mit dem Unternehmen sowie eines durchgängigen Abgleichs der Wissensbasis einher. Die Umsetzung des entstandenen Artefakts, das Artefakt an sich sowie sein Einsatz in der Praxis fließen wiederum in die Wissensbasis ein.

---

Für die kritische Betrachtung der Umweltauswirkungen der für die Digitalisierung notwendigen elektronischen Komponenten mit Fokus auf Seltenerdmetallen wurde eine umfassende Literaturrecherche durchgeführt. Ziel war eine modellhafte Berechnung von IKT-Geräten und die Ermittlung des daraus resultierenden Elektroschrotts. Die Arbeit soll den mit der Digitalisierung verbundenen Rebound-Effekt anhand der Nutzung elektronischer Geräte und somit eine differenzierte Betrachtung der offensichtlichen Vorteile des Einsatzes von IKT verdeutlichen. Dafür wurden im ersten Schritt das Vorkommen in der Natur und die Hauptanwendungsgebiete der einzelnen Seltenerdmetalle im Elektronikbereich identifiziert. Im Anschluss wird ein Überblick über den Gewinnungsprozess sowie das Recycling und die Entsorgung gegeben und Substitutionsmöglichkeiten aufgezeigt. Anschließend erfolgt die modellhafte Berechnung der IKT-Geräte, wobei die zuvor identifizierten Daten auf die Länder mit einem sehr hohen Human Development Index extrapoliert wurden. Aus diesen Werten wurde in Verbindung mit der Lebensdauer der einzelnen IKT-Geräte die Recyclingquote abgeleitet und das Gesamtaufkommen an Elektroschrott ermittelt.

## **5. Publikationsübersicht: Methoden und Ergebnisse**

Im folgenden Kapitel werden die Publikationen mit ihrer Zielstellung, der Methodik und der Ergebnisse dargestellt. Publikation 1 und 2 bauen aufeinander auf. Sie beschreiben die Umsetzung des maschinellen Lernens durch Random Forest (1. Publikation) sowie der Entwicklung eines künstlichen neuronalen Netzes (2. Publikation) an dem Szenario des Kunststoffunternehmens. Beiden Verfahren liegen die gleichen Daten zugrunde. Publikation 3 betrachtet übergeordnet das Thema des Rebound-Effekts im Zuge der Digitalisierung und Automatisierung. Dabei wird der Fokus auf Seltenerdmetalle gelegt, da diese Elemente in sämtlichen Geräten der Informations- und Kommunikationstechnologie zum Einsatz kommen und deren Gewinnung und Entsorgung zu besonders starken Umweltbelastungen führt. Die

---

Betrachtung der kritischen Nebeneffekte, welche durch die zahlreichen positiven Möglichkeiten der in allen Lebensbereichen vorhandenen Digitalisierungs- und Automatisierungstechniken entstehen, ist ein wichtiger Aspekt für die Beurteilung der ganzheitlichen Umweltauswirkungen von IKT und sollte daher entsprechend gewürdigt werden.



Abbildung 11: Zusammenhang der Publikationen (Eigene Darstellung, erstellt mit Unterstützung von DALL-E 2)

Tabelle 2: Publikation 1: "Machine Learning for Optimization of Energy and Plastic Consumption in the Production of Thermoplastic Parts in SME"

Machine Learning for Optimization of Energy and Plastic Consumption in the Production of Thermoplastic Parts in SME	
<b>Zielstellung:</b> Entwicklung eines Random Forest-Modells zur Überwachung und Optimierung des Plastikabfalls und des Energieverbrauchs in einem kunststoffproduzierenden KMU	
<b>Methodik:</b>	<b>Technologien, Bibliotheken, Frameworks:</b>
Datenerhebung und –bereinigung von 4 Produktionsmaschinen (M64, M67, M68, M69) mit 34 Merkmalen und insgesamt 777.458 Datensätzen über einen Erfassungszeitraum von 4 Monaten;	OPC-Schnittstelle, Modbus RTU, SQL
Datenverständnis	Pandas, NumPy, PyCharm

<b>Machine Learning for Optimization of Energy and Plastic Consumption in the Production of Thermoplastic Parts in SME"</b>	
Auswahl des Algorithmus	Überwachtes Lernen, Random Forest-Algorithmus
Datenvorverarbeitung	Pandas, PyCharm
Modellerstellung (Aufteilung des Datensatzes in Test- und Trainingsdaten; Erstellen der Hyperparameter; Auswertung aller Kombinationen von Hyperparametern des Entscheidungsbaum; Ermittlung der Wichtigkeit der Merkmale (gewichteter Mittelwert); Erklärung der Ergebnisse mit LIME	Random Forest, Scikit-learn, Hyperopt, PyCharm
Modelloptimierung und -test (Anpassung Datensatz, Anpassung Hyperparameter)	SQL, Random Forest, Scikit-learn, Hyperopt, PyCharm
Modellanalyse, Interpretation der Ergebnisse	LIME, NumPy, PyCharm
<b>Ergebnisse:</b> <ul style="list-style-type: none"> <li>• Empfohlenen Maschineneinstellungen für eine Reduzierung des Energieverbrauchs/Teil [Wh]</li> <li>• Empfohlenen Maschineneinstellungen für die Verbesserung der Qualität/Teil [%]</li> </ul>	

Tabelle 3: Ergebnisse der RF-Modelle

<b>M64</b>		
<b>Parameter</b>	<b>Wert</b>	<b>Qualitätsverbesserung pro Teil [%]</b>
Umschaltvolumen_K2 [cm <sup>3</sup> ]	3,8<x<4,1	4
Umschaltspritzdruck_K2 [mbar]	x>685	6
Maximaler_Spritzdruck_K2 [mbar]	x>685	4

Einspritzzeit_K2 [s]	$0,34 < x < 0,35$	29
Dosierzeit_K1 [s]	$x > 5,75$	2
Dosierzeit_K2 [s]	$x < 6,3$	14
Zylinderheizzone_1_K1 [°C]	$x = 190 \text{ C}$ oder $x = 204$	14
Zylinderheizzone_1_K2 [°C]	$219,5 < x < 220,3$ oder $x = 224,5$	39
Zylinderheizzone_2_K2 [°C]	$x = 204,5$	5
Zykluszeit [s]	$x > 31,42$	15
<b>Parameter</b>	<b>Wert</b>	<b>Energieeinsparung pro Teil [Wh]</b>
Massepolster_K2 [cm <sup>3</sup> ]	$x > 3$	10
Umschaltvolumen_K2 [cm <sup>3</sup> ]	$x > 3,45$	13
Umschaltspritzdruck_K2 [mbar]	$x > 742$	15,5
Maximaler_Spritzdruck_K2 [mbar]	$x > 724$	45
Einspritzzeit_K2 [s]	$x > 0,37$	25
Dosierzeit_K1 [s]	$x < 5,7$	5
<b>M67</b>		
<b>Parameter</b>	<b>Wert</b>	<b>Qualitätsverbesserung pro Teil [%]</b>
Massepolster_K1 [cm <sup>3</sup> ]	$x = 8,4$	4
Umschaltspritzdruck_K1 [cm <sup>3</sup> ]	$x > 712$	2
Dosierzeit_K1 [s]	$x = 5,15$	3

Zylinderheizzone_1_K1 [°C]	$267,1 < x < 269,3$	8
Zylinderheizzone_2_K1 [°C]	$x > 274,2$	8
Zylinderheizzone_4_K1 [°C]	$x > 279,2$	2
Zylinderheizzone_8_K1 [°C]	$x = 285$	12
Werkzeugheizkreis_1 [°C]	$x = 79,5$	9
Parameter	Wert	Energieeinsparung pro Teil [Wh]
Massepolster_K1 [cm <sup>3</sup> ]	$x > 11$	5
Umschaltvolumen_K1 [cm <sup>3</sup> ]	$x < 22$	10
Zylinderheizzone_2_K1 [°C]	$x < 275$	2
Integral (Druck über Zeit) [mbar/s]	$x > 870$	3
<b>M68</b>		
Parameter	Wert	Qualitätsverbesserung pro Teil [%]
Einspritzzeit_K2 [s]	$x = 0,342$	8
Zylinderheizzone_1_K1 [°C]	$x = 194,5$	8
Werkzeugheizkreis_2 [°C]	$x = 72,1$	20
Parameter	Wert	Energieeinsparung pro Teil [Wh]
Zykluszeit [s]	$x > 33,5$	2,5
<b>M69</b>		

Parameter	Wert	Qualitätsverbesserung pro Teil [%]
Massepolster_K1 [cm <sup>3</sup> ]	$6,1 < x < 6,6$	15
Dosierzeit_K1 [s]	$x = 5,26$	5
Zylinderheizzone_1_K1 [°C]	$x > 243,3$	18
Zylinderheizzone_2_K1 [°C]	$x = 244,1$	16
Zylinderheizzone_3_K1 [°C]	$x = 245,6$	8
Temperiergeraet_1_Werkzeug [°C]	$x = 25,8$	3
Parameter	Wert	Energieeinsparung pro Teil [Wh]
Werkzeugheizkreis_3 [°C]	$x > 210$	8
Zykluszeit [s]	$x > 22,8$	9

Da nicht alle Maschineneinstellungen in der Praxis geändert werden können, werden für die Berechnung der Ergebnisse auf ein Jahr prognostizierte Energiewerte auf Basis der Modelle angenommen. Bei der Betrachtung der Maschine M68 konnten lediglich Zusammenhänge in der Änderung der Zykluszeit und dem Energieverbrauch erkannt werden. Dieser ist mit 2,5 Wh sehr gering und wird daher in der Gesamtprognose nicht betrachtet. Aufgrund der geringen Daten, was auf die niedrige Produktion zurückzuführen ist, ist es durch das RF-Modell nicht möglich, genaue Aussagen zu treffen.

---

Tabelle 4: Prognostizierte Energieersparnis pro Jahr (ML)

	Prognostizierte Energieersparnis pro Teil [Wh]	Produzierte Teile im Messzeitraum	Produzierte Teile pro Jahr	Energieersparnis pro Jahr [kWh]
<b>M64</b>	60	168.917	550.488,438	33.029,31
<b>M67</b>	20	247.052	805.124,821	16.102,5
<b>M68</b>	0	86.203	280.929,42	0
<b>M69</b>	10	275.286	897.137,411	8.971,37
<b>Gesamt</b>				<b>58.103,18</b>

Wie in Tabelle 4 dargestellt, ergibt sich eine Energieeinsparungen von ca. 58.100 kWh/Jahr und CO<sub>2</sub>-Einsparungen bei einem Faktor von 474 g/kWh (Icha & Kuhs, 2019) von 27.540 kg/Jahr.

Tabelle 5: Publikation 2: "Neural Networks for Energy Optimization of Production Processes in Small and Medium Sized Enterprises"

<b>"Neural Networks for Energy Optimization of Production Processes in Small and Medium Sized Enterprises"</b>	
<b>Zielstellung:</b> Entwicklung eines KNN zur Überwachung und Optimierung des Plastikabfalls und des Energieverbrauchs in einem kunststoffproduzierenden KMU	
<b>Methodik:</b>	<b>Technologien, Bibliotheken, Frameworks:</b>
Datenvorverarbeitung von 4 Produktionsmaschinen (M64, M67, M68, M69) mit 34 Merkmalen und insgesamt 777.458 Datensätzen über einen Erfassungszeitraum von 4 Monaten	SQL, Pandas, PyCharm

<b>“Neural Networks for Energy Optimization of Production Processes in Small and Medium Sized Enterprises”</b>	
Modellerstellung (Aufteilung des Datensatzes in Test- und Trainingsdaten; L2-Regularisierung, Dropout, Anpassung Hyperparameter	Scikit-learn, Hyperopt, NumPy, PyCharm
Modellanalyse, -optimierung und -test: <ul style="list-style-type: none"> <li>• Anpassung Hyperparameter</li> <li>• Modell: Predict Function als Black Box</li> <li>• Optimierung der Eingabewerte (Maschineneinstellungen) durch Kombination der Vorhersagefunktionen für Energie und Qualität</li> <li>• Parametertest in einem Radius r mit der Abweichung der wahren Parameterwerte von den vorhergesagten Werten</li> <li>• Metrik: Abwandlung des Standardfehlers</li> </ul> Interpretation der Ergebnisse	Scikit-learn, Hyperopt, NumPy, LIME, PyCharm
<b>Ergebnisse:</b> Empfohlenen Maschineneinstellungen für eine Reduzierung des Energieverbrauchs/Teil [Wh] <b>und</b> Verbesserung der Qualität/Teil [%]	

Im Gegensatz zum RF-Verfahren wurden bei der Ermittlung der empfohlenen Maschineneinstellungen gleichzeitig sowohl die Energie als auch die Qualität betrachtet. Dabei wurden die Hyperparameter des Netzes jedoch auf die Energieersparnis optimiert.

Tabelle 6: Ergebnisse des KNN

<b>M64</b>			
<b>Parameter</b>	<b>Wert</b>	<b>Qualitätsverbesserung pro Teil [%]</b>	<b>Energieeinsparung pro Teil [Wh]</b>
Umschaltvolumen_K2 [cm <sup>3</sup> ]	x=4,429	-5,69	32,28
Zylinderheizzone_1_K1 [°C]	x=206,504	6,65	-4,27

Zylinderheizzone_2_K1 [°C]	x=205,44	4,87	6,29
Zylinderheizzone_5_K1 [°C]	x=205,3	-1,36	48,89
<b>M67</b>			
Massepolster_K1 [cm3]	x=17,052	0,13	7,14
Maximaler_Spritzdruck_K1 [mbar]	x=253,559	0,14	0,43
Einspritzzeit_K1 [s]	x=1,503	0,05	0,08
Werkzeugheizkreis_1 [°C]	x=80	0,16	1,24
Die Parameter Massepolster_K1 und Einspritzzeit_K1 können nur gemessen, aber an den Maschinen nicht umgestellt werden. Daher werden sie im Endergebnis nicht betrachtet.			
<b>M68</b>			
Bei Maschine M68 standen nicht genug Daten für das Training des Energiemodells des KNN zur Verfügung, daher konnten keine Ergebnisse erzielt werden.			
<b>M69</b>			
Zylinderheizzone_1_K1 [°C]	245,338	0,06	0,11
Zylinderheizzone_4_K1 [°C]	244,877	0,04	0,47

Im Endergebnis werden nur die Einstellungen betrachtet, die Energie einsparen, ohne die Qualität zu verringern und eine gewisse Signifikanz besitzen. Diese empfohlenen Parameter sind in Tabelle 7 dargestellt.

Tabelle 7: Prognostizierte Energieersparnis pro Jahr (KNN)

	<b>Empfohlener Parameter</b>	<b>Energieersparnis pro Teil [Wh]</b>	<b>Produzierte Teile pro Jahr (interpoliert)</b>	<b>Energieersparnis pro Jahr [kWh]</b>
<b>M64</b>	Zylinderheizzone_2_K1	6,29	550.488,438	3.462,57
<b>M67</b>	Maximaler_Spritzdruck_K1, Werkzeugheizkreis_1	1,67	805.124,821	1.344,56
<b>M69</b>	Zylinderheizzone_1_K1, Zy- linderheizzone_4_K1	0,58	897.137,411	520,34
<b>Gesamt</b>				<b>5.327,47</b>

Daraus ergibt sich eine Energieeinsparungen von ca. 5.327 kWh/Jahr und CO2-Einsparungen bei einem Faktor von 474 g/kWh (Icha & Kuhs, 2019) von 2.525 kg/Jahr.

Tabelle 8: Publikation 3: "Rebound Effects in the Use of Rare Earth Metals in ICT"

<b>"Rebound Effects in the Use of Rare Earth Metals in ICT"</b>	
<b>Zielstellung:</b> Betrachtung der mit der Digitalisierung verbundenen Rebound-Effekte bezogen auf Seltenerdmetalle	
<b>Methodik:</b>	<b>Technologien, Bibliotheken, Frameworks:</b>
Literaturrecherche und Datensammlung <ul style="list-style-type: none"> <li>• Physikalische/chemische Grundlagen von Seltenerdmetallen</li> <li>• Vorkommen und Anwendungsgebiete</li> <li>• Betrachtung der Umweltaspekte bei der Förderung und Verarbeitung, Extraktion, Recycling, Entsorgung und Substitution</li> </ul>	Wissenschaftliche Datenbanken, Fachliteratur

**“Rebound Effects in the Use of Rare Earth Metals in ICT”**

Modellhafte Berechnung der IKT-Geräte und der Recyclingrate weltweit (basierend auf den 66 Ländern mit einem HDI ab 0,8)

RStudio

**Ergebnisse:** Insgesamt 66 Länder konnten einen HDI  $\geq 0,8$  erreichen (United Nations, 2011). Bei der Berechnung der Hochrechnung wird davon ausgegangen, dass die IKT-Ausstattung der Bürger in den einzelnen Ländern grundsätzlich ähnlich ist. Diese Länder haben eine Gesamtbevölkerung von 1,57 Milliarden Menschen (United Nations, 2020). Daraus ergibt sich eine angenommene Anzahl von IKT-Geräten von 7 Milliarden. Angesichts der kurzen Lebensdauer von IKT-Geräten zwischen etwa 2,5 Jahren für Smartphones und 5 Jahren für andere digitale Geräte ist die Menge an Elektroschrott immens. Nach 10 Jahren sind dies rund 68 Milliarden IKT-Geräte. Unter der Annahme einer Recyclingquote von 5 % innerhalb der EU und 1,5 % in anderen Ländern (Gröger, 2020) beträgt die Gesamtmenge an Elektroschrott 67 Milliarden nicht recycelte Elektro-Geräte.

Die besondere Herausforderung dieser Arbeit lag in der äußerst mangelhaften und invaliden Datenlage über die gesamte Prozesskette der Gewinnung, der Verarbeitung und des Recyclings. Daher war es lediglich möglich, eine modellhafte Auswertung auf Basis von hochgerechneten Daten durchzuführen.

## 6. Zusammenfassung und aktuelle Herausforderungen

Die beiden Verfahren – Anwendung des maschinellen Lernens mit dem Random Forest-Algorithmus sowie die Entwicklung eines künstlichen neuronalen Netzes – wurden auf 4 Maschinen mit insgesamt 777.458 Datensätzen angewendet.

Tabelle 9: Ausgangsdaten der einzelnen Maschinen

Maschine	Anzahl Datensätze	Gutteile		Schlechtteile	
		Absolut	Relativ [%]	Absolut	Relativ [%]
M64	168.917	166.232	98,41	2.685	1,59

Maschine	Anzahl Datensätze	Gutteile		Schlechtteile	
		Absolut	Relativ [%]	Absolut	Relativ [%]
<b>M67</b>	247.052	245.982	99,60	1.070	0,43
<b>M68</b>	86.203	85.325	99,00	878	1,02
<b>M69</b>	275.286	270.780	98,40	4.506	1,64
<b>Gesamt</b>	<b>777.458</b>	<b>768.319</b>	<b>98,85</b>	<b>9.139</b>	<b>1,17</b>

Die Endergebnisse zwischen den beiden Verfahren des Random Forest und der künstlichen neuronalen Netze weisen einen gravierenden Unterschied auf. Das resultiert aus dem Vorgehen bei beiden Verfahren. Beim RF wurden die Energie- und Qualitätsmodelle einzeln betrachtet, um dann einen Zusammenhang herzustellen. Die empfohlenen Parameterwerte pro Maschine unterscheiden sich jedoch danach, ob Qualität oder Energie betrachtet wird. Das KNN konnte die optimalen Parametereinstellungen für beide Betrachtungselemente ermitteln. Betrachtet man beispielsweise die Maschine M64, ermittelt der RF-Algorithmus, dass der Parameter Umschaltspitzdruck\_K2 die Qualität um 6 % und die Energie um 15,5 Wh verbessern kann. Die optimale Einstellung für die Qualitätsverbesserung ist ein Wert über 685 mbar und für die Energieverbesserung über 742 mbar. Das KNN liefert für diese Maschine die Empfehlung, den Parameter Zylinderheizzone\_2\_K1 auf 205,44 °C anzupassen, um eine Qualitätsverbesserung von 4,87 % und ein Energieersparnis von 6,29 Wh pro Teil zu erreichen.




Abbildung 12: Ergebnisse des RF-Algorithmus für M64




Abbildung 13: Ergebnisse des KNN für M64

Bei Maschine M67 wurde durch RF die höchste Energieersparnis von 10 Wh bei einem Umschaltvolumen\_K1 über 22 cm<sup>3</sup> und die höchste Qualitätsverbesserung von 12 % bei Änderung der Zylinderheizzone\_8\_K1 auf 285 °C ermittelt. Eine kombinierte Verbesserung beider Elemente kann durch Adaption von Massepolster\_K1 um 8,4 cm<sup>3</sup> für Qualität (4%) und auf >11 cm<sup>3</sup> für Energie (5 Wh) erreicht werden. Auch das KNN ermittelte die höchsten Energieersparnis für Massepolster\_K1 um 7,14 Wh sowie eine Qualitätsverbesserung um 0,13 % bei einem Wert von 17,052 cm<sup>3</sup>.

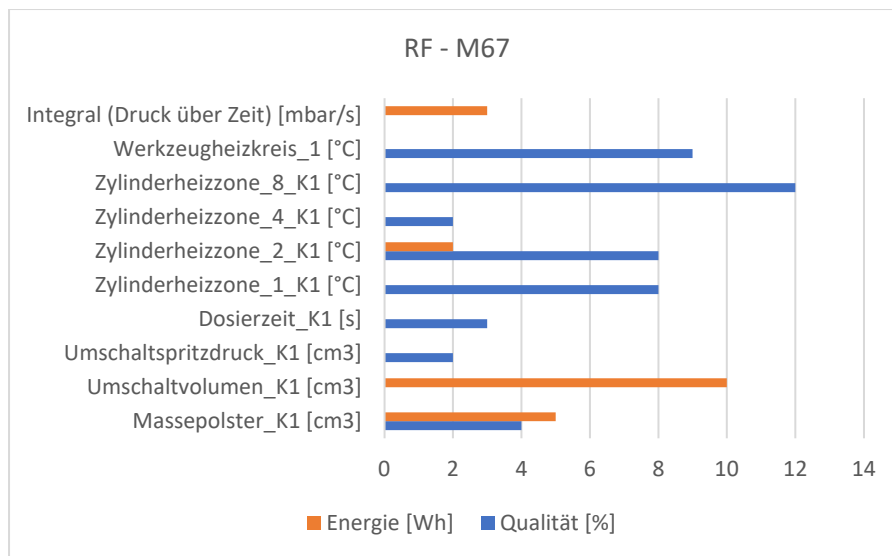


Abbildung 14: Ergebnisse des RF-Algorithmus für M67




Abbildung 15: Ergebnisse des KNN für M67

Bei der Validierung der Ergebnisse im Unternehmen ergab sich jedoch, dass die Parameter Massepolster\_K1 und Einspritzzeit\_K1 nicht verstellbar sind. Der RF-Algorithmus erkennt keine Optimierungsmöglichkeiten bei Maximaler\_Spritzdruck\_K1, jedoch eine Qualitätsverbesserung von 9 % bei Werkzeugheizkreis\_1 bei 79,5 °C. Das KNN schlug die Einstellung auf 80 °C bei 0,16 % Qualitätssteigerung und 1,24 Wh Energieeinsparung vor. Bei Maschine M68 wurden durch RF eine Optimierungsmöglichkeit hinsichtlich Energie um lediglich 2,5 Wh erkannt. Allerdings ergab die Auswertung klare Spitzen bei Qualitätsverbesserungen bei Änderung der Parameter

Werkzeugheizkreis\_2 (20%) sowie Einspritzzeit\_K2 und Zylinderheizzone\_1\_K1 um jeweils 8%. Das KNN konnte aufgrund der geringen Datenmenge von 86.203 Datensätzen nicht trainiert werden. Daher sind für diese Maschine keine Aussagen möglich.




Abbildung 16: Ergebnisse des RF-Algorithmus für M68

Für Maschine M69 fand der RF-Algorithmus keine Änderung für die Kombination von Energie und Qualität. Hohe Qualitätsverbesserungen sind bei den Parametern Massepolster\_K1 (15% bei Einstellungen im Bereich von 6,1 – 6,6 cm<sup>3</sup>), Zylinderheizzone\_1\_K1 (18% bei Einstellung über 243,3 °C) und Zylinderheizzone\_2\_K1 (16% bei 244,1 °C) zu erwarten. Eine Energieersparnis von 8 Wh wird bei der Änderung der Einstellung Werkzeugheizkreis\_3 auf > 210 °C und von 9 Wh bei einer Zykluszeit von über 22,8 s prognostiziert. Auch das KNN schlägt eine Änderung der Zylinderheizzone\_1\_K1 auf 245,338 °C vor. Der empfohlene Wert beträgt 245,338 °C um 0,06 % Qualitätsverbesserung und 0,11 Wh Energieersparnis zu erreichen. Für eine Ersparnis von 0,47 Wh und 0,04 % Qualitätsverbesserung sollte die Zylinderheizzone\_4\_K1 auf 244,877 °C eingestellt sein.

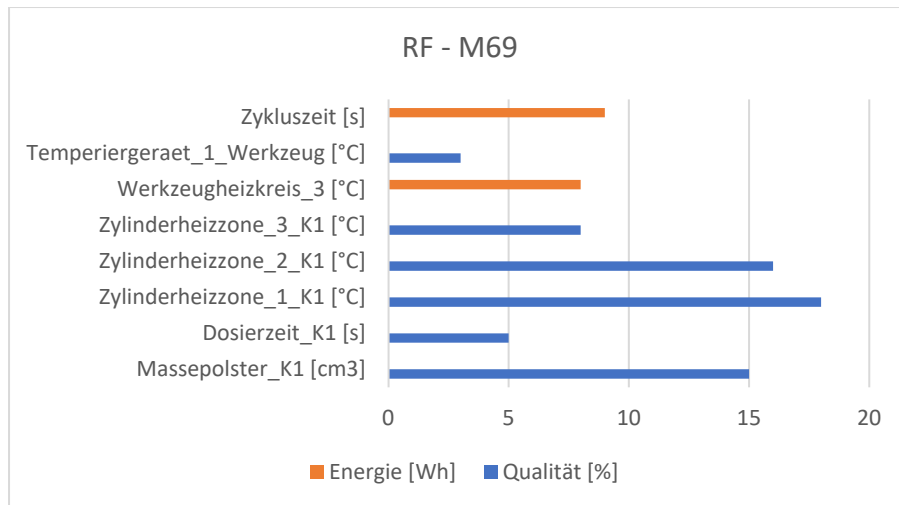


Abbildung 17: Ergebnisse des RF-Algorithmus für M69

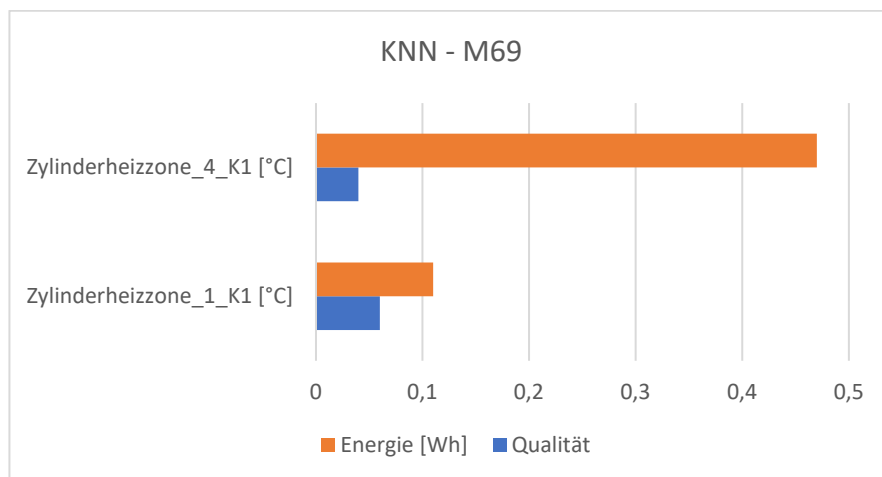


Abbildung 18: Ergebnisse des KNN für M69

Random Forest ist einer der ML-Algorithmen, der dafür ausgelegt ist, Daten zu klassifizieren und Muster und Korrelationen zu finden, auf deren Basis es Entscheidungen trifft. Jedoch weisen diese Muster nicht unbedingt auf einen kausalen Zusammenhang hin. Diese Anpassungen müssen beim Algorithmus manuell vorgenommen werden. Das KNN ist jedoch in der Lage, durch Anpassung der Gewichte und eine ausreichende Menge an Datensätzen, automatisiert zu lernen. Außerdem erzielen die ermittelten Daten eine höhere Genauigkeit. Dadurch ist es genauer, be-

nötigt jedoch mehr Entwicklungszeit und eine hohe Menge an Daten. Zusammenfassend kann gesagt werden, dass durch die Verwendung eines KNN eine höhere Aussagekraft erzielt werden kann.

Die Forschungsergebnisse zeigten, dass KI-Anwendungen die Ressourcennutzung in KMU optimieren kann. Wie bereits beschrieben, gibt es jedoch in KMU besondere Hemmnisse, die es zu bewältigen gilt.

Im Rahmen der Tätigkeit an der HTW Berlin bestand auch neben dem Dissertationsprojekt ein stetiger Austausch mit produzierenden KMU. Dabei wurde immer wieder deutlich, dass diese generell aufgeschlossen gegenüber der Einführung von KI sind. Allerdings werden die KI-Technologien als sehr unübersichtlich empfunden. Die Leuchtturmprojekte, welche beispielsweise auf der Plattform für Künstliche Intelligenz aufgezeigt werden, können nicht ohne Expertenwissen an die individuellen Bedürfnisse der jeweiligen KMU angepasst werden. Gegenstand weiterer Forschung wäre, standardisierte und einsatzfähige KI-Module anhand der häufigsten Anwendungsfälle produzierender Unternehmen zur Verfügung zu stellen. Beispielsweise können angepasste unternehmensbezogene Softwarelösungen auf der Plattform „IT2match“ (Mittelstand 4.0-Kompetenzzentrum - IT Wirtschaft) angeboten werden. Dort werden Unternehmen und Softwareentwickler entsprechend ihrer Bedürfnisse und Angebote zum digitalen Workflow vernetzt. Eine KI-Plattform für verschiedene Anwendungsfälle mit entsprechender Vernetzungsmöglichkeit für Unternehmen und Entwickler wäre eine zukünftige Möglichkeit, intelligente Lösungen in KMU einzuführen.

In erster Linie sollten bei der Einführung von KI weniger komplexe technische Systeme genutzt werden. Die hier vorgestellten Algorithmen sind ohne erheblichen personellen und finanziellen Aufwand in die IT der meisten Betriebe integrierbar. Weiterhin ist dadurch eine einfachere Adaptierbarkeit auf ähnliche Problemstellungen gegeben. Besonders die Kopplung einer intelligenten Kreislaufwirtschaft mit intelligenter Prozessoptimierung kann vielversprechend für ökologisches Produzieren

---

unter ökonomischen Gesichtspunkten sein. Durch die Verknüpfung mit Prozessorik (Kombination von Sensoren und Aktoren) an den Maschinen und Fahrzeugen wird ein automatisierter Prozessablauf gebildet, der weitere ökologische Potenziale unter Nutzung von KI-Verfahren aufdecken kann. Es steht außer Frage, dass die Digitalisierung einen entscheidenden Einfluss auf die effiziente Produktion hat und der Optimierung und somit der Kostenersparnis für die Unternehmen dient. Jedoch führt sie in ihrer Gesamtheit auch zu ökologischen Problemen. Neben steigendem Energiebedarf für Rechenzentren, der hohen Nachfrage an Metallen für Hardware sowie der geringen Verweildauer von IKT-Geräten beim Konsumenten findet nur ein sehr begrenztes Recycling der IKT-Geräte statt. Das liegt zum einen an den hohen Kosten der Recyclingverfahren bezogen auf die moderaten Rohstoffpreise aber auch an den technisch anspruchsvollen Methoden bei der Rückgewinnung von Seltenerdmetallen. Schwierigkeiten ergeben sich aus dem geringen Vorkommen der Seltenerdmetalle in den Endgeräten, der starken Verdünnung der Schmelze des E-Schrotts („Downcycling“) sowie der dissipativen Verteilung dieser Elemente. Kommerzielles Recycling von Seltenerdmetallen wird bisher nur bei Leuchtstoffen, Magneten und Batterien durchgeführt (U.S. Department of the Interior & U.S. Geological Survey, 2021). Weiterhin sind die herkömmlichen Recyclingprozesse (mechanische Verarbeitung, Pyro- und Hydrometallurgie, Reduktion von Legierungen der Seltenerdmetalle) äußerst energie- und kostenintensiv. Neben dem Recycling ist auch die Förderung und Gewinnung dieser Elemente mit hohen Umweltrisiken verbunden. Durch den entstehenden Abraum kommt es zu einem sehr hohen Flächenbedarf, die massiven physikalischen Eingriffe in die Bodenstruktur schädigen die Ökosysteme. Es fallen große Mengen gefährlicher Abfälle und Rückstände wie die Freisetzung radioaktiver Elemente und Schwermetalle sowie Silikate und Laugungschemikalien an. Die Ausbreitung von Stäuben giftiger Substanzen durch Wind und Schutt gelangt ins Ödland und ins Grundwasser. Da es bisher noch keine befriedigende Lösung zur Substitution der Seltenerdmetalle gibt, wäre eine Kombination langlebiger IKT-Geräte mit nutzerfreundlichem Service wie Wartung und Reparatur

---

denkbar. Dies könnte auch zu einer Änderung im Konsumentenverhalten und somit zu einer längeren Nutzung der Geräte führen. Nicht zuletzt sind globale Investitionen in die Forschung zur Entwicklung ökologischerer Abbau- und Gewinnungs- sowie Recycling- und Substitutionsverfahren notwendig.

## 7. Kumulativer Teil der Dissertation

### 1: Machine Learning for Optimization of Energy and Plastic Consumption in the Production of Thermoplastic Parts in SME



Article

## Machine Learning for Optimization of Energy and Plastic Consumption in the Production of Thermoplastic Parts in SME

Martina Willenbacher <sup>1,\*</sup>, Jonas Scholten <sup>2</sup> and Volker Wohlgemuth <sup>2</sup>

<sup>1</sup> Institute of Environmental Communication, Leuphana University Lüneburg, 21335 Lüneburg, Germany

<sup>2</sup> Industrial Environmental Informatics Unit, Department Engineering-Technology and Life, Hochschule für Technik und Wirtschaft Berlin (HTW), University of Applied Sciences Berlin, 10318 Berlin, Germany; jonas.scholten@posteo.de (J.S.); volker.wohlgemuth@htw-berlin.de (V.W.)

\* Correspondence: martina.willenbacher@htw-berlin.de

**Abstract:** In manufacturing companies, especially in SMEs, the optimization of processes in terms of resource consumption, waste minimization, and pollutant emissions is becoming increasingly important. Another important driver is digitalization and the associated increase in the volume of data. These data, from a multitude of devices and systems, offer enormous potential, which increases the need for intelligent, dynamic analysis models even in smaller companies. This article presents the results of an investigation into whether and to what extent machine learning processes can contribute to optimizing energy consumption and reducing incorrectly produced plastic parts in plastic processing SMEs. For this purpose, the machine data were recorded in a plastics-producing company for the automotive industry and analyzed with regard to the material and energy flows. Machine learning methods were used to train these data in order to uncover optimization potential. Another problem that was addressed in the project was the analysis of manufacturing processes characterized by strong non-linearities and time-invariant behavior with Big Data methods and self-learning controls. Machine learning is suitable for this if sufficient training data are available. Due to the high material throughput in the production of the SMEs' plastic parts, these requirements for the development of suitable learning methods were met. In response to the increasing importance of current information technologies in industrial production processes, the project aimed to use these technologies for sustainable digitalization in order to reduce the industry's environmental impact and increase efficiency.

**Keywords:** machine learning; artificial intelligence; reduction of emissions and material; energy saving; sustainability



**Citation:** Willenbacher, M.; Scholten, J.; Wohlgemuth, V. Machine Learning for Optimization of Energy and Plastic Consumption in the Production of Thermoplastic Parts in SME. *Sustainability* **2021**, *13*, 6800. <https://doi.org/10.3390/su13126800>

Academic Editor: Silvia Fiore

Received: 5 March 2021

Accepted: 28 May 2021

Published: 16 June 2021

**Publisher's Note:** MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



**Copyright:** © 2021 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

### 1. Introduction

In these times of industrialization and digitalization, it is becoming increasingly important to build a sustainable economy. The CO<sub>2</sub> balance of companies plays a major role in this. A further challenge is the environmental pollution caused by plastics, which many industrial companies use and therefore have to eliminate.

The challenges in building a sustainable economy are complex. They require appropriate solutions. One field of information technology is discussed particularly frequently: Artificial Intelligence, and Machine Learning. While large companies have entire departments for the development and implementation of machine learning, small- and medium-sized companies are hesitant to enter this field. SMEs face some challenges in the field of digitalization. SMEs perceive digitization as complex and expensive and in some cases do not see the necessity. In contrast to large companies, failed attempts can quickly lead to financial and personnel difficulties in small companies. The study "Potentials of artificial intelligence in the manufacturing industry in Germany", commissioned by the Federal Ministry of Economics and Energy, came to the conclusion that a lack of internal competence in the manufacturing industry is one of the biggest obstacles to the use of AI

technologies. Only 15% of SMEs in Germany use AI in their respective value-added stages to date. The degree of automation of process control based on AI is also still extremely low [1]. The professional qualifications of employees in the field of artificial intelligence are also only moderately developed. The University of Saarland studied 200 SMEs in 8 EU countries and found that at the present time only 15% of the companies enable their employees to acquire AI-relevant qualifications. The survey of the companies revealed that only 19% use AI applications in their companies [2]. A study by KfW Research even found a value of only 5% in 2020 for the use of AI applications in SMEs [3].

This paper describes the development of a prototype to monitor and optimize waste minimization and energy savings in an SME in the plastics industry using machine learning.

Artificial intelligence is a combination of engineering science and cognitive science. The goal is to translate human performance and perception in terms of cognitive abilities into a technical system. Thus, applications for problem cases are to be developed that could previously only be solved by human actions [4]. The basic requirements for research with AI are thus an understanding of algorithms, data structures, and combinatorics, which makes AI part of the field of theoretical computer science [5] and statistics. As a sub-item of AI, machine learning is one of the most advanced methods of data analysis and data processing [6]. The connection between computer (machine) and human (learning) already implies the basic idea of technology: to learn and predict by analogy with the brain. Machine learning has the goal of learning from data, creating a model, and using this model to make predictions [7]. One of the main applications of machine learning is the creation of adaptive systems and the generation of knowledge from large amounts of data to create a picture of reality [8] and to enable the system to solve problems on its own. Machine learning distinguishes 3 methods: Supervised learning, empowered learning, and unsupervised learning. In supervised learning, a model is created using trained data sets. Encouraging learning serves to develop a system that improves through interaction with its environment. Unsupervised learning is supposed to find patterns without being given precise guidelines. The choice of the learning procedure is based on the scenario and the problem [9].

Unsupervised learning processes data without labels. In this case, however, the entries are already categorized. This ignores information that is already known, which means that an inaccurate result is to be expected. In addition, the goal is already clearly defined: reducing misproduction and lowering energy consumption. A clustering analysis could possibly form groups that have similar properties but which do not contribute to answering the research question. With appropriate interpretation, it might be possible to obtain results, but by incorporating all the available information, especially the labels, the other types of machine learning promise more success. The application of reinforcement learning is one possible way to deliver results. However, one basic requirement was not met for this: interaction with the environment. In this project, already collected data was available. To use this method, the algorithm had to make direct changes to the machine by adjusting the parameters with the results [10]. Even if promising results could be obtained in theory, the financial effort is too high in comparison to the possible potential savings from the research findings. The prerequisites for supervised learning are fully met in this case.

Pre-marked data are available and it is defined how this information is to be analyzed and optimized. Based on this, models can be created and checked for accuracy. Consequently, the method of supervised learning was used.

## **2. Materials and Methods**

### *2.1. Data Exploration and Data Validation*

For the prototype development, the data of 4 different machines of a production plant with a total number of more than 60 machines were evaluated. The data were not only collected and trained offline, but also during ongoing production operations. In addition, indirect factors (e.g., maintenance intervals, mechanical faults) were also taken into account. The data were collected via OPC interfaces developed in the project and protocols of the

ISO standard-defined Modbus RTU. This required a systematic configuration of the IT department. These data are collected in a SQL database. In the first step, the data are viewed and pre-processed. After selecting a suitable machine learning algorithm, a model is generated and analyzed. Approximately 800,000 data sets are considered over a data acquisition period of 4 months. In the first step, the dataset is examined and the required parameters are selected.

Data without information gain are removed from the calculation to increase the calculation time of the model. In this case, these are the attributes tool, material and program. On the whole, the data can be used for machine learning, but the interruptions in the data acquisition lead to an increased effort in filtering and preparing the data. Table 1 contains the recorded machine parameters, which are collected in the database.

**Table 1.** Description of the database columns.

Description of Database Columns
Date and time of shot
Unique identifier of DB
Name of the machine
Applied tool
Program name used during operation
Applied thermoplastic material
Quality per shot, 1: error-free piece 3: erroneous piece
Shots since program restart
Duration of production of the piece
Compensating mass for contraction on cooling of the piece
The process is switched over from this volume value (repressing)
Pressure for repressing
Maximum pressure of the process
Duration of filling in the mold
Duration of the melting process for the next process
Heating zones for granulate melting
Control of the temperature of the tool
Water temperature to control the tool heating circuit
Cumulative pressure over time
Energy meter reading of the corresponding machine

Figure 1 shows an overview of the available data per machine and parameter. Black markings stand for existing entries, and white markings symbolize data not entered. In the upper bar are the parameters, on the left are the corresponding machine designations, and on the right the number of data per machine. As you can see, all machines have completely white entries for some attributes. These are not missing data; rather, due to the different construction methods these measured values are not collected; for example, the cylinder heating zone does not exist. In general, a complete data set is available. Noticeable are the gaps in cylinder heating zone\_K2\_(3,4,5) for machine M69. Due to the coherent, missing data, it can be assumed that in this case the production of the machine was changed over, where these areas are not used.




Figure 1. Data amount per machine.

### 2.2. Selection of the Appropriate Learning Method

At this point, the appropriate learning method for the goals of reducing error production and lowering energy consumption should now be determined. Unsupervised learning processes data without labels. In this case, however, the entries are already categorized. This means that information already known is ignored, which leads to an inaccurate result. Furthermore, the targets are already clearly defined. A clustering analysis could possibly form groups that have similar characteristics but do not contribute to answering the research questions. The application of reinforcement learning is one possible way to deliver results. However, a basic prerequisite for this is not given: interaction with the environment. Data already collected in the project are available. To use this method, the algorithm would have to make direct changes to the machine and use the results to adjust the parameters. The prerequisites for supervised learning are completely fulfilled in this case: pre-labelled data exist and they are defined by the way this information should be analyzed and optimized. Based on this data, models can be created and checked for accuracy. Consequently, the method of supervised learning is used.

### 2.3. Selection of the Appropriate Algorithm

Before individual algorithms are evaluated, the requirements must first be described. With about 600,000 complete data sets, there is a large amount of information that has to be processed. No assumptions can be made about the model; therefore, non-linear relationships should also be recognized when creating it. The problem requires that a method not only makes correct predictions, but is also interpretable and can explain the reasons why a decision is made. In the best case, the model should be created in as short a time as possible, since the analysis period is limited and costly calculations over several days can quickly impede the completion of tasks. The objective includes the explanation of quality in the form of a discrete classification, as well as a continuous estimation in the form of a regression for energy consumption. Optimally, the algorithm should be able to handle both types in order to reduce the development effort. In addition, a low risk of over-adaptation would be advantageous in order to obtain a general model.

#### 2.3.1. Support Vector Machines

Support Vector Machines are able to perform both linear and non-linear classifications [11]. Furthermore, a regression and a classification are carried out [12]. The classifiers are only described by their support vector and are therefore less susceptible to over-customization. However, the kernel functions have this property, and therefore the problem is shifted from the hyper parameters to the kernel selection [13]. Furthermore, SVMs do not scale precisely enough for large data sets, because they are designed for smaller quantities. The reason for the decision not to use this algorithm for this work is its limited interpretability [14].

### 2.3.2. Artificial Neural Networks

Artificial neural networks are very promising. A large amount of data is even a basic requirement for this algorithm. In addition, a complex model can be created, and thus non-linear relationships can be mapped [15]. Neural networks can be used to represent both classifications and regressions. For satisfactory functioning, however, a large number of hyper parameters must be determined, which indicate how the basic structure of the neural network is constructed [16]. Compared to other machine learning algorithms, training the neural network requires significantly more computational effort [17].

### 2.3.3. Random Forest Algorithm

The Random Forest Algorithm offers the possibility to map a large number of data sets and parameters in one model [18]. What distinguishes its interpretability from other methods is its insight into the decisions that take place in the individual trees [19]. For a more comprehensive explanation, Random Forest is also supported by the LIME algorithm. Another specific feature is a low level of pre-processing. Data can be used directly without standardization or normalization. The algorithm is also robust against missing data. However, one of the greatest strengths is its tolerance for overfitting [20]. Due to the random selection of data sets, this circumstance only occurs in rare cases. The models work for both regression and classification [21]. Both the random forest and the neural networks are applicable to the present scenario. Considering its speed of model generation and its easier insight into the decision criteria for classifications, the random forest algorithm is therefore used.

## 2.4. Implementation

After selecting the machine learning algorithm, the implementation now follows. In the following, the influence of the parameters on the quality is examined first. In the database, a faultlessly produced plastic part is stored with 1, and an incorrect part with 3. For the random forest algorithm, there are therefore two labels to be classified: “quality good” and “quality bad”. For this purpose, the quality column is stored in isolation in a variable after the database has been read in.

### 2.4.1. Preprocessing

The first step is to consider which parameters should be excluded from the analysis. The shot\_ID is a unique identifier of the database and does not contain any information of the machine. Excluding this column prevents the algorithm from remembering individual data records based on the ID. The logged time and date in the Machine\_Timestamp column behave similarly. The size Shot\_after\_Restart derived from the Shot\_ID is also neglected. These parameters are not useful for later statements about changes in machine settings. The Program, Tool, and Material columns contain only one value for each machine, which makes them superfluous. This also applies to all data fields that contain zeros.

### 2.4.2. Setup of Random Forest

In the next step the data set is divided into training and test data. As test data size, 25% is chosen. The algorithm divides the data randomly. Random numbers are usually generated by a deterministic algorithm. These are called pseudo-random numbers because, although they are statistical, they are not actually random due to their predictability. By knowing one generated number in sequence, all other values can be calculated [22]. Every generator needs a starting value, the so-called seed, which is set together with the random variable in this case. Predictability is advantageous in this environment because it guarantees that the same subdivision is made every time the program is started. Thus, later hyper parameter adjustments are comparable. Otherwise, changes in the result could also be due to the fact that other subdivisions have taken place. Now, the hyper parameters for the Random Forest Algorithm are created. For the first run, default values are used to verify the function of the script. Then, the model with the training data is created using the

fit method according to the algorithm from the theory part. Then, the algorithm predicts the labels of the test data. The accuracy score function compares the prediction with the correct results and returns the percentage detection rate.

In the next step, the model must be adapted for optimal detection. For this purpose, it is first of all necessary to find out which is a suitable evaluation method for a good model. The result from the last section calculated in Figure 2 is 99.2%. This represents the percentage of correctly classified parts. At first glance, this figure seems to be a good result. However, the value depends on the distribution of input data. In this case, the proportion of good parts is 98.4%. An algorithm that always predicts a good part would therefore have a classification accuracy of 98.4%. The aim is to reduce the number of faulty parts and their causes. Therefore, a good representation of bad parts in the random forest model is a high priority. For this purpose the confusion matrix is consulted. This describes how many good parts and how many bad parts are correctly identified.



Figure 2. Explanation from LIME.

With this detailed insight into the result of the model, better statements about its quality can be made. While the good parts were detected almost 100% correctly, the bad parts are not yet within an acceptable range, with a detection rate of about 71%. A target of 90% is aimed for. Within this range it can be assumed that no overfitting has taken place and the model has generalized the data sets. The number of data sets (about 42,000) is the chosen 25% test portion of the total measured data, this can be seen in Table 2.

Table 2. Classification in dependency of the labels.

	Error-Free Pieces	Erroneous Pieces
Classification: Error-free pieces	41.510	188
Classification: Erroneous pieces	9	471

In further experiments, some hyper parameters will be adjusted for test purposes. If the number of trees is increased to 150, the detection rate even drops to 72% for bad parts, while good parts continue to be correctly classified at almost 100%. Increasing the tree depth from 6 to 10 with otherwise identical parameters results in a classification rate of 41,510/41,519 (approx. 100%) for good parts and 596/711 (83.4%) for bad parts. This indicates an increase. With the increased depth, however, indirect storage of the data records is more likely. A tree with as many leaves as records could have a separate Create\_path. Another test evaluates the under sampling: Up to now, the ratio between error-free and error-prone data was about 99:1. However, a composition of 50:50 would be optimal. Therefore, in this test all bad parts are used and the same number of good parts are randomly read from the database, see this in Table 3. With this balanced data set, the Random Forest Model is again used with the parameters:

- min\_samples\_leaf: 3;

- n\_estimators: 100;
- min\_samples\_split: 10;
- max\_features: sqrt;
- max\_depth: 6;
- max\_leaf\_nodes: None.

**Table 3.** Classification rate with balanced dataset.

	Error-Free Pieces	Erroneous Pieces
Classification: Error-free pieces	656	3
Classification: Erroneous pieces	3	655

Now, the classification rate is very high in both parts. It can be assumed that overfitting is taking place.

#### 2.4.3. Selection of the Optimal Hyper Parameters

After randomly testing some hyperparameter combinations, a method is developed to determine the optimal hyperparameter in a structured way. Since each parameter combination takes about 5 min, batch processing is implemented to test different arrangements. For the program of the batch, the following parameters are permuted in all combinations:

- balanced\_dataset = [True, False];
- machine\_options = ['M64', 'M67', 'M68', 'M69'];
- min\_samples\_leaf\_options = [3, 5, 7, 10, 30, 50];
- n\_estimators\_options = [10, 30, 50, 100];
- min\_samples\_split\_options = [5, 10, 20, 30, 50];
- max\_depth\_options = [3, 4, 5, 10];
- max\_leaf\_nodes\_options = [unlimited, 2, 5, 10].

This gives a total of 15,360 results, which are stored in the database. The detection rates of the good and bad parts are entered as absolute and percentage values, as well as the selection of the hyper parameters. Due to the precalculations, the results of the hyperparameter combination can now be output immediately. For this purpose, a graphical tool is created in which the suitable parameters are selected by mouse click and the results from the database can be displayed. With this tool, the hyper parameters can now be determined in such a way that the recognition for good and bad parts is about 90%.

#### 2.4.4. Analysis of the Model

Now, a model exists which can classify data sets with a high probability. However, the desired research result is more complex. Thus, not only an answer for a single data set should be provided, but also an explanation of the model. It should give an exact indication of the area in which the best performance of the machines is achieved, so that waste is reduced, less plastic is produced, and less CO<sub>2</sub> emissions are produced.

For this purpose, the local Brutforce method is used with the LIME [23] explanation algorithm developed by Ribeiro, Singh, and Guestrin. The tool was written in Python and R, and stands for Local Interpretable Model-Agnostic Explanations. LIME is used to generate the explanation of the prediction of any classifier or regressor based on text, tables or images in machine learning, thereby making an approximate understanding of complex models possible. LIME is based on finding independent explanations locally and for each instance, and on fitting simple models locally to the predictions of the complex model. These simplified models make the complex data model interpretable. Instead of trying to create a global model, this method can provide explanations for the environment of a particular data set. For this purpose, the method generates random samples in the environment at equal intervals and weights them according to their distance from the original point. From this, the algorithm delivers a linear explanatory model. This can be displayed graphically for visualization.

On the left are the predictions of the random forest, on the right are the values that the individual parameters have, and the middle shows the explanations of LIME. This result can be used to analyze the decisions for a single data set. However, it is not yet possible to derive and formulate a general statement. The next step is therefore to provide an explanation for each test data set. In the first iteration, occurrences of the display formats specified in the above list are counted and evaluated. Since the generation of the explanations may take some time and memory errors may occur, the results are stored temporarily in a file. For reproducibility and dynamic processing, the hyper parameters, the machine, the LIME parameters, and the generation date are stored in the first line of the file in addition to the explanations. For this purpose, a dictionary is added to the Explainer class as a parameter. For the first test, however, only the most important labels are included. In the next step these are to be grouped and plotted. The search is performed using regular expressions and the required parameter values are extracted. In a dictionary, the arranged value ranges are counted and sorted. Now, more precise statements can be made.

First of all, it is noticeable that considerably more bad than good parts are listed in a diagram. The reason for this is the diagram's sorting according to importance. As described above, only the four most important labels for each data set are included in the evaluation. Thus, it can be interpreted that the injection time is less important for the classification of a faultless production than for a classification of a faulty part. Looking at the relative sizes of the graph within a classification, the result is that the good quality between 0.31 and 0.36 is a clear maximum. Conversely, a significant drop can be seen at this point with poor quality, whereas outside this area there is a high rate.

#### 2.5. Adapting to Energy Analysis

Now, this procedure is transferred to the energy analysis. In addition to the pre-processing of the data, further aspects must be taken into account in the energy analysis. The absolute value of the energy meter is stored in the database after completion of a product. However, the variable to be analyzed is the energy consumption per plastic part produced. For this purpose, the difference of two data sets following each other in time is formed. For a first plausibility check, the energy consumption per time thus obtained is plotted in Figure 3.




Figure 3. Energy consumption over time for machine 4.

It is obvious that further data filtering must take place. On closer inspection, it is noticeable that the peaks always occur after periods of time in which no data are available. From this it can be concluded that at these points in time, the complete recording of all parts was interrupted. The consequence in the calculation is that for the first part after a longer

break, the energy which was used for all parts in the interruption period is calculated. Two possible causes for the gaps in the data sets are connection problems in the infrastructure or the crash of the data acquisition script. The data records contain the cycle time information, which describes how long the machine needs to produce a part. The average cycle time for Machine 4 is 22.83 s. This time can be selected as an indicator for missing data records. A threshold value of 60 s between two data sets is defined. If the time difference is greater than this, the respective data set is ignored for the energy analysis. This already gives a more conclusive picture. There are also energy differences of 0 Wh, which are also excluded from the analysis for plausibility reasons. In addition, one is only interested in those production runs in which a proper plastic part was produced. Data sets with quality = 3 are therefore not taken into account.

#### Technical Implementation

Since the data acquisition is interrupted at some points, a time difference between two data sets must be created for the check. When working with databases, data integrity should be maintained at all times. This means that the time difference is not added to the table production log of the machines, but the separate table energy difference is created, with a reference to the ID in the production log. This has the advantage that in the case of errors, the original data in the production log remain unchanged, and changes can be undone by resetting the energy difference. In the first step, after connecting to the database, an empty array is initiated, which has the length of the data to be written. Since for the difference two consecutive values are always required, the first entry in the array must be initiated with a placeholder for an invalid value. In this case the common  $-1$  is used. A missing hour in the data is conspicuous—followed by an apparently double data series, whose energy counter rises and falls. The reason for this is the time changeover on 31 March. The problem is solved by sorting by shot\_ID. In general, it is noticeable that the energy series is largely constant. The noise in the signal can be attributed to the sensor's accuracy of 10 Wh. This has the consequence that the values alternate between two to three steps of 10. Some peaks are visible, but these are probably due to missing measurement data that the filtering from the previous section could not capture. At machine 1, on 17 May 2019, at 13:12, the energy consumption suddenly increases from about 170 Wh to 250 Wh. For analysis with Machine Learning, this device is most promising due to this significant difference, and can be used as a validator of the later algorithm. Figure 4 shows the energy consumption per plastic part over time.

From the basic structure, the algorithm of energy analysis is close to that of quality analysis. A model is created, which is interpreted with LIME, and finally, plotted. The only difference is in the labels: While the discrete values 1 and 3 were present for the quality analysis, a continuous range is possible for the energy analysis. This changes the evaluation of the hyper parameters used. When analyzing quality, a binary statement existed: correct or incorrect classification. This method could also be used for continuous values. However, to evaluate these as incorrect with minimal deviations from the original value leads to a seemingly bad algorithm in many data sets. A better evaluation is therefore to consider the relative deviation. This also improves the interpretation of individual predictions. It can be said not only whether a forecast is incorrect, but also how incorrect the forecast is. This also leads to the fact that—in contrast to the evaluation of quality—there is no unbalanced data set. Therefore, all entries for the machine can be used. Errors in production can lead to increased energy consumption. Therefore, only those data sets describing a faultless plastic part were considered in the energy analysis. In the next step, the hyper parameter combinations are tested again and finally the best Configuration is selected. Table 4 shows the optimal values for each machine.




Figure 4. Cont.

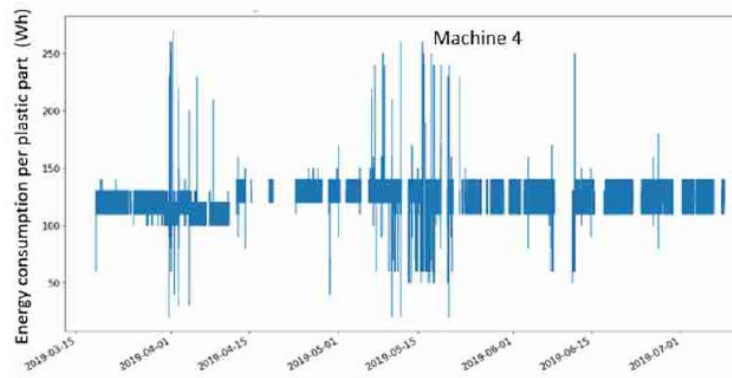


Figure 4. Energy consumption over time.

Table 4. Selected hyper parameters per machine.

Parameter	M 1	M 2	M 3	M 4
min_samples_leaf	100	80	200	100
n_estimators	20	70	50	40
min_samples_split	1000	800	1100	900
max_depth	3	3	6	4
max_leaf_nodes	20	30	30	20

Figure 5 shows the project procedure as an overview.

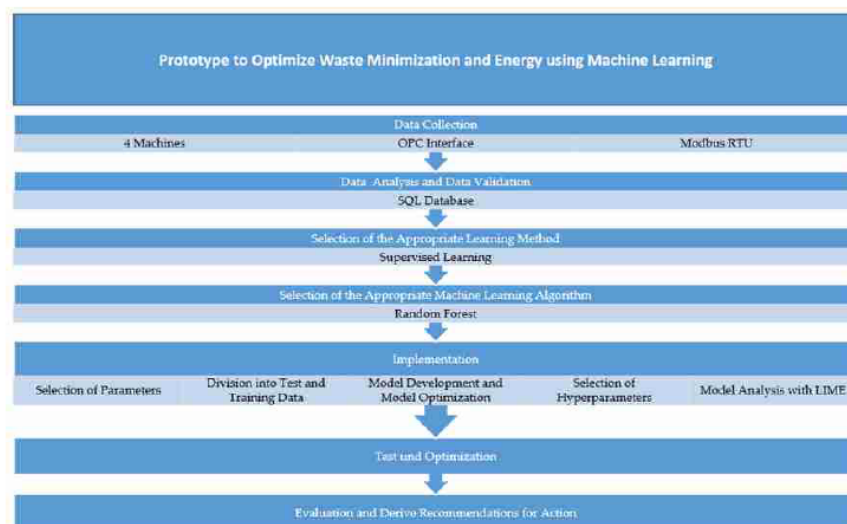


Figure 5. Project procedure.

### 3. Results

#### 3.1. Interpretation of the Diagrams

When viewing the diagrams, different types of curves can be grouped together. During processing with LIME, premature filtering of the most important features was deliberately prevented, so that it is only during interpretation that a decision has to be made as to how relevant a feature is. As a result, a suitable selection must be made afterwards. It is therefore important to first consider the scale of the *y*-axis (probability or energy). A relevance of at least 1% for quality and 2 Wh for energy was chosen as a prerequisite for their respective inclusion in the evaluation. Figure 6a shows, for example, a clear increase in quality between 91.8 °C and 92.4 °C. However, the difference in probability (0.005) is too small to make a sound statement. Figure 6b is similar. However, there is the additional fact that no preferences can be determined from the curve shape. Here, a classical noise signal is present. Even filtering through the minimum number of data sets does not produce any improvement. With a few exceptions, only one data set per point is shown in this diagram. Occasionally, there are diagrams like Figure 6c in which very few *x*-values exist. Here, a small variance can already be seen in the raw data. Possible reasons for this could be a low resolution during data collection or a defective sensor.

Figure 6d shows the optimum case. Here, there is a relative difference of 50 Wh, the curves show a clear trend for optimum spray pressure above 740 mbar, and the noise of the values is very low. Another consideration should be taken into account when assessing the importance: In some diagrams the values are permanently below zero, thus always contributing to a bad part classification. This could lead to the conclusion that the feature is irrelevant, since no value contributes to good part detection. However, the relative value of two references is always decisive. Based on the diagrams, the results are presented for each machine. The results are read from the remaining diagrams with significant significance. For each characteristic, a recommendation is made as to which are the optimum machine settings. In addition, the size of the influence for classification into a good part is indicated. For the difference in relevance, the range between the smallest and largest value is shown (Figure 7a). The diagrams can be divided into three categories: Some charts cannot be classified into an optimal range. However, it is clearly visible at which points the result deteriorates. Therefore, the recommendation is given as a range above this range (Figure 7b). On the other hand, there is a peak in the diagram that can be clearly read (Figure 7c). There are also cases where noticeable peaks can be seen in two places (Figure 7d).




Figure 6. Evaluation of different diagrams (1).




Figure 7. Evaluation of different diagrams (2).

### 3.2. Recommended Actions for the Machine Settings

#### 3.2.1. Machine 1

For machine 1, a large amount of data was collected, with about 168,000 entries. The high ratio of 1.6% bad parts is important for the evaluation of the quality of the advantageous parts, see this in Table 5. Detailed results can therefore be expected. The same applies to the consideration of energy. In contrast to other machines, there was a jump here, which should lead to a good classification.

**Table 5.** Recommendation for quality.

Feature	Recommendation	Relevance Difference (Probability)
Duration of the melting process for the next process	5.75 s	0.02
Duration of filling in the mold	$0.34 \text{ s} < x < 0.35 \text{ s}$	0.29
Maximum pressure of the process	$685 \text{ mbar} < x$	0.04
Pressure for repressing	$685 \text{ mbar} < x$	0.06
The process is switched over from this volume value	$3.8 \text{ cm}^3 < x < 4.1 \text{ cm}^3$	0.04
Duration of production of the piece	$x > 31.42 \text{ s}$	0.15
Heating zones for granulate melting 1	190 °C or 204 °C	0.14
Heating zones for granulate melting 2	$219.5 \text{ °C} < x < 220.3 \text{ °C}$ or $x = 224.5 \text{ °C}$	0.39
Heating zones for granulate melting 3	204.5 °C	0.05

Especially clear maxima can be calculated in the quality analysis for the characteristics' duration of filling in the mold and cylinder heating zone\_1. With 29% and 39%, there is a considerable predictable reduction in the number of parts produced in error. Clear patterns have been established for energy. The highest optimization is used for the characteristic \_maximum\_ energy. Furthermore, there are savings of 25 Wh possible for injection time and 15.5 Wh for switch-over injection pressure. Under the assumption that the values influence each other, an overall estimate with 60 Wh/part is a very conservative forecast, which in practice can be significantly higher. See the recommendation for energy in Table 6.

**Table 6.** Recommendation for energy.

Feature	Recommendation	Energy Difference (Wh)
Duration of the melting process for the next process	5.75 s	5
Duration of filling in the mold	$x > 0.37 \text{ s}$	25
Compensating mass for contraction	$x > 3 \text{ cm}^3$	10
Maximum pressure of the process	$x > 742 \text{ mbar}$	45
Pressure for repressing	$x > 742 \text{ mbar}$	15.5
The process is switched over from this volume value	$x > 3.45 \text{ cm}^3$	13
Duration of the melting process for the next process	5.75 s	5

#### 3.2.2. Machine 2

Machine 2 has about 267,000 entries; the second largest data set of the considered machines. During the period under consideration, a low rate of faulty production of 0.4% was achieved. With 1070 bad parts, the analysis nevertheless shows good results are possible, see this in Table 7. The energy consumption over time shows a constant distribution, with individual periods of reduced energy. It was therefore to be expected that patterns for an optimization can be recognized. A clear result, as with machine 1, is not to be expected.

Table 7. Recommendation for quality.

Feature	Recommendation	Relevance Difference (Probability)
Duration of the melting process for the next process	5.15 s	0.03
Compensating mass for contraction on cooling	8.4 cm <sup>3</sup>	0.04
Pressure for repressing	x > 7112 mbar	0.02
Control of the temperature of the tool	79.5 °C	0.09
Heating zones for granulate melting 1	267.1 °C < x < 69.3 °C	0.08
Heating zones for granulate melting 2	x > 274.2 °C	0.08
Heating zones for granulate melting 3	x > 279.2 °C	0.02
Heating zones for granulate melting 4	285 °C	0.12
Duration of the melting process for the next process	5.15 s	0.03

The evaluation of quality shows several possibilities for improvement, which are between 8% and 12%. The cylinder heating zones are particularly present. The mold heating circuit shows a clear maximum at 79.5 °C, at which point the probability is 9% higher than the minimum. For energy optimization, there is only a significant difference in the switching volume (10 Wh). Nevertheless, the results of all characteristics allow a saving of 20 Wh/part forecast. See this recommendation for energy in Table 8.

Table 8. Recommendation for energy.

Feature	Recommendation	Energy Difference [Wh]
Pressure over time	x > 870 mbar/s	3
Compensating mass for contraction on cooling	x > 11 cm <sup>3</sup>	5
The process is switched over from this volume value	x < 22 cm <sup>3</sup>	10
Heating zones for granulate melting	x > 275 °C	2

### 3.2.3. Machine 3

Machine 3 has the smallest amount of information, with about 86,000 data records. In addition, less than 1000 data were classified as bad parts. In terms of energy consumption over time, the scatter of values is minimal on this machine, and therefore, expectations regarding the results are low. With regard to energy, only correlations with the cycle time were detected, and this is 2.5 Wh at a low level. No savings are therefore made in terms of energy consumption, as predicted by changed attitudes. The situation is different for quality. There, a clear peak can be seen in the mold heating circuit, which shows a difference of 20% for the quality prognosis, check Table 9.

Table 9. Recommendation for quality.

Feature	Recommendation	Relevance Difference (Probability)
Duration of filling in the mold	0.342 s	0.08
Control of the temperature of the tool	72.1 °C	0.2
Heating zones for granulate melting 1	194.5 °C	0.08

With 8% in each case, the change of the injection time and, for the cylinder heating zone\_1, a reduction in the number of missing parts can be predicted. All in all, there is little potential for optimization in practical tests on machine 3, see Table 10 for the recommendation for energy. Few data have their origin in the lower production, compared to the other machines. This means that this device, anyway, is less relevant for the total savings.

**Table 10.** Recommendation for energy.

Feature	Recommendation	Energy Difference [Wh]
Duration of production of the piece	$x > 33.5$ s	2.5

#### 3.2.4. Machine 4

For machine 4, the most entries in the database are available, with about 275,000. The high rate of missing parts of 1.6% provides a good data basis for the patterns behind the good and bad quality classifications. The energy consumption over time shows a constant straight line, which, however, reduces energy consumption section by section. In the results for quality, the cylinder heating zones, with values between 8% and 18%, have a significant impact, see Table 11.

**Table 11.** Recommendation for quality.

Feature	Recommendation	Relevance Difference (Probability)
Duration of the melting process for the next process	5.26 s	0.05
Compensating mass for contraction on cooling	$6.1 < x < 6.6$ cm <sup>3</sup>	0.15
Water temperature to control the tool heating circuit	25.8 °C	0.03
Heating zones for granulate melting 1	$x > 243.3$ °C	0.18
Heating zones for granulate melting 2	244.1 °C	0.16
Heating zones for granulate melting 3	245.6 °C	0.08
Duration of the melting process for the next process	5.26 s	0.05

The mass cushion shows a large noise component in the diagram. In the recommended range between 6.1 cm<sup>3</sup> and 6.6 cm<sup>3</sup>, however, a clear straight line and an improved probability for good parts can be found. With regard to energy consumption, there are two characteristics that influence energy: the tool heating circuit and the cycle time. In both cases there is a point where the energy level drops rapidly. If the machine settings are adjusted accordingly, energy savings of 10 Wh/part can be expected, see Table 12.

**Table 12.** Recommendation for energy.

Feature	Recommendation	Energy Difference (Wh)
Control of the temperature of the tool	210 °C	8
Duration of production of the piece	$x > 22.8$ s	9

In terms of quality, it is often the characteristics that control the temperature that are decisive. The cylinder heating zone in particular has an influence on the quality of every machine without exception. When looking at the origin of the data, a correlation is conclusive: If the granulate is not at the right temperature for the plastic, it may dry too quickly or too slowly. If the produced part falls out of the injection mold into the output, deformations can occur afterwards if the heat is too high, which can damage the product. If the temperature is too low, the liquefied granulate may be too tough and may not fill the mold completely, which also leads to rejection. In terms of energy, no similarities between the machines can be seen. The analysis must therefore be carried out again for each machine. Nevertheless, significant differences in some of its characteristics are evident.

For energy savings, the measurement period is 112 days. This value is interpolated to 12 months in order to make statements about energy savings per year, see Table 13.

**Table 13.** Prediction of energy savings per machine.

	Potential Savings Energy per Piece (Wh)	Produced Pieces in Measuring Period	Interpolated for a Year	Energy Saving per Year (kWh)
M 1	60	168,917	550,488.44	33,029.31
M 2	20	247,052	805,124.82	16,102.5
M 3	0	86,203	280,929.42	0
M 4	10	275,286	897,137.41	8971.37
				58,103.18

In total, for the four machines, savings of about 58,100 kWh are predicted. Based on the Federal Environment Agency's recommendations, a value of 474 g CO<sub>2</sub> per kWh is assumed for CO<sub>2</sub> reduction. This results in a potential reduction of 27,540 kg CO<sub>2</sub> per year for the four machines.

#### 4. Discussion

By using the Random Forest Algorithm, the information could be used efficiently and precisely to create a model. With the help of the LIME method, diagrams were created from which patterns could be interpreted. The resulting findings provide answers to the research questions: Machine learning methods can show that the individual parameters of the machines influence quality and energy consumption. The potential electricity reduction is 27,540 kg CO<sub>2</sub> per year for the four machines under consideration. The next step is to test the results obtained on the machines and verify their effects in practical use. This procedure is of elementary importance. The collected data only represent a section of the real environment, both in the spatial and temporal components. A correlation between two parameters gives only an indication, but cannot provide a basis for proof between cause and effect. An interesting investigation for future work is a global approach, where the individual machines are not considered, but their entirety. For example, external influences such as temperature fluctuations in the production hall could be detected, and new optimization possibilities could be found. On the software side, there are also approaches that can still be pursued. For example, the application of a neural network could lead to further results. For the interpretation of the models, it has to be evaluated whether other methods can be used to achieve more meaningfulness. Presently, the parameters are independent of each other. A multi-dimensional view, which analyses combinations of settings, has the potential to reveal further energy savings. However, current work shows that the use of machine learning in SMEs can provide hidden avenues for energy savings and a reduction in faulty production.

#### 5. Conclusions

In the plastics processing company studied, several scenarios are conceivable for the further expansion of digitalization. If the material flow management system and the necessary data sources cover the entire operation, various possibilities will be created. It is conceivable that through the entire intelligent monitoring of the production cycle, further potential optimization opportunities can be found in the areas of resource efficiency, machine utilization, and the use of operating resources. Opportunities for savings and optimization potential can also be assumed outside of production. One area that could be worthwhile is material procurement: Procurement can be optimized by predicting the required raw materials in combination with a market analysis. Maintenance intervals and necessary repairs can also be better planned and carried out at an early stage before damage occurs. Likewise, logistics (fuel or electricity costs) and production (utilization of machines or planning of personnel, etc.) can lead to higher efficiency. With regard to the operational environmental area, it will be important to substitute and allocate resources, or, alternatively, to avoid them and to find and use new savings avenues. Machine learning can play a key role here, as it is very applicable to the data requirements of the environmental sector—large, heterogeneous data volumes, different formats and

sources. Conceivable scenarios range from the analysis and prediction of environmental data during operations and the resulting control and monitoring of production, to self-learning production processes. Machine learning is a forward-looking technology and is currently also gaining ground in the environmental sector. However, digitalization presents SMEs with a number of challenges. More than half of all businesses see themselves as laggards in this area [24]. SMEs perceive digitalization as complex and expensive and in some cases do not see the need for it. Likewise, in most companies, the human resources required for implementation are not available. In contrast to large companies, failed attempts in small firms can also quickly lead to financial difficulties [25]. At this point in time, it can be concluded that digitalization and especially the use of artificial intelligence in SMEs is still too uncertain and that they are largely clinging to their old structures.

**Author Contributions:** Conceptualization, M.W. and V.W.; methodology, M.W.; software, M.W. and J.S.; validation, M.W. and J.S.; formal analysis, M.W.; investigation, M.W. and J.S.; resources, M.W.; data curation, M.W.; writing—original draft preparation, M.W. and J.S.; writing—review and editing, M.W., J.S. and V.W.; visualization, M.W. and J.S.; supervision, V.W. and M.W.; project administration, M.W.; funding acquisition, V.W. All authors have read and agreed to the published version of the manuscript.

**Funding:** In cooperation with Novapax Kunststofftechnik Steiner GmbH & Co. KG, the University of Applied Sciences Berlin is working on the implementation of a prototype in the Nova [26] research project to monitor and optimize waste minimization and energy savings in an SME in the plastics industry using machine learning. This research was funded by Deutsche Bundesstiftung Umwelt, grant number 34589/10.

**Institutional Review Board Statement:** Not applicable.

**Informed Consent Statement:** Not applicable.

**Data Availability Statement:** The data in this study are available on reasonable request from the corresponding author.

**Conflicts of Interest:** The authors declare no conflict of interest.

## References

1. Gabriel, P. *Potenziale der Künstlichen Intelligenz im Produzierenden Gewerbe in Deutschland*; Begleitforschung PAiCE, iit-Institut für Innovation und Technik in der VDI/VDE Innovation + Technik GmbH: Berlin, Germany, 2018; p. 5.
2. Kaul, A.; Schieler, M. *Künstliche Intelligenz im Europäischen Mittelstand: Status quo, Perspektiven und was Jetzt zu tun ist*; University of Saarland: Saarbrücken, Germany, 2019.
3. Zimmermann, V. *Künstliche Intelligenz: HOHE Wachstumschancen; Aber Geringe Verbreitung im Mittelstand*, KfW Research Fokus Volkswirtschaft, Nr. 318; KfW: Frankfurt/Main, Germany, 2021.
4. Russell, S.; Norvig, P. *Artificial Intelligence: A Modern Approach*, 3rd ed.; Pearson: Upper Saddle River, NJ, USA, 2009; Chapter 1.
5. Poole, D.; Mackworth, A.K.; Goebel, R. *Computational Intelligence: A Logical Approach*; Oxford University Press: New York, NY, USA, 1998; Chapter 1.
6. Bönisch, M. Konzept zur Einführung von Maschinellem Lernen im Kontext der Betrieblichen Nachhaltigkeit in Mittelständischen Unternehmen. Master's Thesis, University of Applied Sciences Berlin, Berlin, Germany, 2019.
7. Alpaydin, E. *Maschinelles Lernen*; Oldenbourg: Oldenburg, Germany, 2004.
8. Görz, G.; Rollinger, C.-R.; Schneeberger, J. (Eds.) *Handbuch der Künstlichen Intelligenz*, 5th ed.; Oldenbourg Verlag: Oldenburg, Germany, 2014; Chapter 11.
9. EMC Education Services. *EMC Services, Data Science and Big Data Analytics: Discovering, Analyzing, Visualizing and Presenting Data*; Wiley: Indianapolis, IN, USA, 2015; Chapter 7.
10. Maimon, O.; Rokach, L. *Data Mining and Knowledge Discovery Handbook*; Series in Solid-State Sciences; Springer: Boston, MA, USA, 2010; Chapter 12.
11. *EMC Services, Data Science and Big Data Analytics: Discovering, Analyzing, Visualizing and Presenting Data*; Wiley: Indianapolis, IN, USA, 2015; Chapter 5.
12. Dean, J. *Big Data, Data Mining, and Machine Learning: Value Creation for Business Leaders and Practitioners*; Wiley and SAS Business Series; Wiley: Indianapolis, USA, 2014; Chapter 5.
13. Willenbacher, M.; Wohlgemuth, V. Machine Learning for Sustainable Logistics. In Proceedings of the EnviroInfo 2019, Kassel, Germany, 23–26 September 2019.

14. Willenbacher, M.; Wohlgenuth, V. Einsatzmöglichkeiten von Methoden der Künstlichen Intelligenz zur Optimierung von Stoff- und Energieströmen und prototypische Umsetzung auf der Basis von Stoffstromnetzen. In *Nachhaltige Betriebliche Umweltinformationssysteme*; Springer: Wiesbaden, Germany, 2018.
15. Kotu, V.; Deshpande, B. *Data Science: Concepts and Practice*; Elsevier Science: Amsterdam, The Netherlands, 2018.
16. Nisbet, R.; Miner, G.; Yale, K. *Handbook of Statistical Analysis and Data Mining Applications*; Elsevier Science: Amsterdam, The Netherlands, 2017.
17. Raschka, S. *Python Machine Learning*; Packt Publishing: Birmingham, UK, 2015; p. 90.
18. Lokuciejewski, P.; Marwedel, P. *Worst-Case Execution Time Aware Compilation Techniques for Real-Time Systems, Embedded Systems*; Springer: Dordrecht, The Netherlands, 2010; p. 171.
19. EMC Services, *Data Science and Big Data Analytics: Discovering, Analyzing, Visualizing and Presenting Data*; Wiley: Indianapolis, IN, USA, 2015; Chapter 6.
20. Love, R. *Linux-Kernel-Handbuch: Leitfaden zu Design und Implementierung von Kernel 2.6*; Open Source Library; Addison-Wesley: San Francisco, CA, USA, 2005; p. 433.
21. Ribeiro, M.T.; Singh, S.; Guestrri, C. “Why Should I Trust You?”: Explaining the Predictions of Any Classifier. In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, San Francisco, CA, USA, 13–17 August 2016; pp. 1135–1144.
22. Leeser, D.C. *Digitalisierung in KMU kompakt: Compliance und IT-Security*; IT Kompakt; Springer: Berlin/Heidelberg, Germany, 2019.
23. Lindner, D. *KMU im digitalen Wandel: Ergebnisse empirischer Studien zu Arbeit, Führung und Organisation*; Essentials; Springer: Wiesbaden, Germany, 2018.
24. Research Project “NOVA”. Available online: <http://nova.f2.htw-berlin.de/> (accessed on 22 April 2021).
25. Muhammad, I.; Yan, Z. Supervised Machine Learning Approaches: A Survey. *ICTACT J. Soft Comput.* **2015**, *5*, 947.
26. Rao, D.; Visin, F.; Rusu, A.A.; Teh, Y.W.; Pascanu, R.; Hadsell, R. Continual unsupervised representation learning. In Proceedings of the 33rd Conference on Neural Information Processing Systems (NeurIPS 2019), Vancouver, BC, Canada, 8–14 December 2019.

## 2: Neural Networks for Energy Optimization of Production Processes in Small and Medium Sized Enterprises

### Neural Networks for Energy Optimization of Production Processes in Small and Medium Sized Enterprises



Martina Willenbacher, Volker Wohlgemuth, and Lisa Risch

**Abstract** Due to the highly dynamic development processes of manufacturing companies (economic, demographic, sociological, ecological-biological processes), there are high requirements to find scientific answers to environmentally specific questions, considering the profitability and ensuring ongoing operation, and to integrate the developed models to improve the efficiency of the use of materials for energy reduction into the process flow. Decision-making is thus hampered on the one hand by the achievement of solutions in shortened innovation and production cycles and on the other hand by the complexity of the systems and processes of the environmental sector. Furthermore, there are often organizational obstacles and personnel difficulties in the introduction of intelligent algorithms in SMEs. This article describes the conception and development of an artificial neural network for the optimization of production processes regarding the reduction of energy under the aspect of quality assurance for manufacturing SMEs. It describes the development and implementation of the model for the analysis and adaptation of parameter settings to machines in the production process, which determines the ideal configuration to reduce energy consumption and improve quality. In the test of the model on four machines of a plastic-producing SME, it was proven that a total annual energy saving of 50,000 kWh can be achieved.

**Keywords** Artificial neural networks · Environmental informatics · Resource efficiency

---

M. Willenbacher (✉)  
Leuphana University Lüneburg, Universitätsallee 1, 21335 Lüneburg, DE, Germany  
e-mail: [martina.willenbacher@htw-berlin.de](mailto:martina.willenbacher@htw-berlin.de)

V. Wohlgemuth · L. Risch  
HTW Berlin University of Applied Sciences, Treskowallee 8, 10318 Berlin, DE, Germany

© The Author(s), under exclusive license to Springer Nature Switzerland AG 2023  
V. Wohlgemuth et al. (eds.), *Advances and New Trends in Environmental Informatics*,  
Progress in IS, [https://doi.org/10.1007/978-3-031-18311-9\\_8](https://doi.org/10.1007/978-3-031-18311-9_8)

129

## 1 Introduction

The increase in resource efficiency in SMEs is primarily based on economic goals. The use of energy and materials is a decisive cost factor. In addition, there are political requirements regarding certification and environmental declarations. The regulations of European climate policy are increasing the pressure on competitiveness, especially in international comparisons. Based on the gross production value of 100%, the material costs in the manufacturing industry alone are 42% (Statistisches Bundesamt 2019).

Even though energy costs have been consistently around 2% for years, the manufacturing industry has a very high primary energy consumption of around 3,874 PJ in 2019–2020 (Statistisches Bundesamt 2021).

However, since the material costs from the company's point of view relate to the entire value chain—including the purchase of precursors and semi-finished products—indirect energy costs are also included in the material costs, so that energy consumption must be considered when considering material efficiency. To make matters worse, the energy data for these products can hardly or not at all be determined, especially for imported products. In summary, it can be said that the greatest savings potential for companies from an economic and ecological point of view lies in the cost of materials [8].

Artificial intelligence methods are already being used by many companies [2]. In the area of production, this is used on the one hand for predictive maintenance and for monitoring process states, on the other hand for forecasting process results and thus for early termination or adaptation of processes. This is done through holistic networking of machines with ICT, whereby a large amount of complex data can hardly be analyzed with conventional mathematical evaluation methods, especially in the case of multidimensional nonlinear dependencies. However, only the consideration of different areas of the company enables a better understanding of the entire operating processes and their overarching processes, which then leads to the development and implementation of new and sustainable solutions. According to a McKinsey study, the biggest obstacles to the implementation of AI in companies are the identification of possibilities to efficiently integrate ad measure AI processes into business processes and to obtain the company data that is relevant for this [1]. Furthermore, SMEs lack the appropriate specialists and financing to introduce and implement AI procedures [10]. In the long delaying digitization will only bring disadvantages compared to the pioneers, and there are hardly any faster ways to catch up later. SME are affected by the performance gap between the pioneers and the laggards.

In response to the increasing importance of today's information technologies in industrial production processes, this paper labels the use of intelligent technologies for sustainable digitization to reduce the environmental impact of industry and increase resource efficiency. It describes the development of a neural network for the analysis of the optimal machine parameters within a production process to reduce energy consumption while improving quality. The research focus is on the reliable

modification of the machine parameters with a dense ANN to minimize the energy usage and maximize the number of produced good quality parts.

## 2 Materials and Methods

For the development of the ANN to support the reduction of CO<sub>2</sub> emissions and production wastes by adapting machine parameters for use in SME, the required data is provided by a cooperation partner of the Berlin University of Applied Sciences, a plastics-producing industry. These are in a SQL database. In our model, 4 machines with a total of 777,458 data sets are considered (Table 1).

The records have the following parameters (Table 2).

*Schuss\_ID* is the ID of the data point and has no relevance for the model. *Machine* is the number of the machine. It is used to select the relevant data points for each model. The parameters *Integral*, *Programm*, *Werkzeug*, *Material* and *Schuss\_nach\_Neustart* have no effect on the model since they have the same values throughout and can be removed. *Qualitaet* is the y-values for the quality model, and *Energiezaehler* and *Maschinen\_Zeitstempel* are the basis for the computation of the y-values for the energy model. The quality data mostly consists of good parts.

The other parameters can be used as the x-values for both models. All parameters with an asterisk (\*) are part of a cylinder unit. The unit always consists of different heat zones, starting with the nozzle and ending at the piping. Some parameters can be set at the machines, such as *Zylinderheizzone\**, *Umschaltvolumen\**, *Temperiergeraet\** and *Maximaler\_Spritzdruck\**. They are independent variables since it is possible to change independently at the machines. Other parameters can only be measured, such as cycle time, *Massepolster\**, *Umschaltspritzdruck\**, *Einspritzzeit\** and *Dosierzeit\**. They are dependent variables since it is not possible to set them at the machines. One thing to note is that the quality classification provided in the database is decided by the producing machine based on settings configured in the machine. For example, it can be decided by an operator that parts which took too long fitting the form (*Einspritzzeit*), are faulty by default. Consequently, when fitting the optimal configuration, one can only fit the quality settings on the machine, instead of fitting the configuration for a true optimal quality.

**Table 1** Data sets of the chosen machines

Machine	Number of datasets
M64	168,917
M67	247,052
M68	86,203
M69	275,286

**Table 2** Parameters of data sets

Parameter	Description	Unit
Schuss_ID	Unique identifier	n/a
Maschine	Machine name	n/a
Zykluszeit	Duration of the production of part	S
Massepolster*	Compensation mass for contraction after cooling sown	cm <sup>3</sup>
Umschaltvolumen*	Starting at this volume value the processed is switched	cm <sup>3</sup>
Umschaltspritzdruck*	Pressure for topping up	bar
Maximaler_Spritzdruck*	Maximum pressure in the process	bar
Einspritzzeit*	Duration of filling the form	s
Dosierzeit*	Duration of melting process for next process	s
Zylinderheizzone*	Heat zones for melting the granulate	°C
Werkzeugheizkreis*	Regulation of the temperature of the tools	°C
Tempriegerät*	Water temperature for regulation the tool heat cycle	°C
Integral	Cumulated pressure over time	p/s
Programm	Program used	n/a
Werkzeug	Tool used	n/a
Material	Plastic material used	n/a
Schuss_nach_Neustart	Number of iterations since last reboot	n/a
Qualitaet	Quality: 1 (good) until 3 (bad)	n/a
Maschinen_Zeitstempel	Date and time of production	datetime
Energiezaehler	Energy counter of the corresponding machine	Wh

## 2.1 Data Preparation

Most of this work has been done in the previous phase of this project [11]. It was provided with the database which had been created for this task. In the first phase of the project machine learning algorithms like random forest with LIME (Local Interpretable Model-Agnostic Explanations) [5, 6] and brute force were developed. It was found issues with the energy data, which is recorded in form of a running energy count. When the production wasn't continuous and there was more time than usual in between the shooting of parts, the larger energy count was attributed to these parts. Due to this, some produced parts had large spikes in energy. This was counteracted by discarding all data points where the period was larger than 1 min. The quality data had the values 1 and 3 for good and faulty part respectively, and the values 3 are then changed to 0. Furthermore, there were gaps in the data, it can be assumed that the production was temporarily halted at those points. These data points were discarded as well [11].

## ***2.2 Design of the Neural Network***

The objective of this project is to use neural networks to achieve the goals of optimizing energy usage and quality in production. It started by using a simple dense network for respective energy and quality modelling. The energy values are provided in the unit of Wh and can take any value. Typically for this type of output values, regression is applied. The quality values however are binary, so they can be either 0 (bad quality) or 1 (good quality), binary classification is used for this model. The predict function will return a value between 0 and 1, representing a probability of the parameters to produce a shot of good quality parts. Since there are many more class instances of 1, class weights are used to counteract this imbalance. For our model there are 32 neurons in the first hidden layer and 64 neurons in a second hidden layer. The complexity of the network can be gauged by trying different configurations. A too simplistic network will not reach a sufficient performance, and a too complex network will start overfitting on the training set too quickly.

## ***2.3 Training of the Neural Network***

The neural networks are trained using a split of the dataset. To account for most quality values being 1, class weights are implemented. This way the model does not just blindly predict all outputs to be 1, since with class weights this does not bring about a minimum of the loss function. The hyperparameters of the models are tuned to overfit on the dataset, and subsequently regularization and dropout are added to achieve a better generalization. Then training is stopped now that the models start overfitting. Those models are then the basis for the following parameter configuration optimization, providing the predict functions for each model. In the following, the example of python code of classification for machine M64 is used to illustrate the process of modelling a neural network model. As a starting point, a batch size of 512, a learning rate of 0.001 and 1,500 proved to provide a satisfactory classification result. The results of the classification on the validation set are (Fig. 1).

The model output shows that the length of the validation set is 16,892 data points. The number of positive data points, 16,617, correspond to good parts; the 275 negative data points represent the faulty parts. The number of true negatives is the number of correctly recognized faulty parts, whereas true positives is the number of correctly recognized good parts. False negatives are the parts that are good but are recognized as faulty, and false positives are the faulty parts recognized as good. Since the goal of this model is to recognize faulty parts as accurately as possible to fit responsible parameters, the objective is to maximize the number of correctly recognized faulty parts, and therefore to minimize the rate of false positives. In this model, the rate is 2.9%, which represents a very good classification. It is important to add regularization to make the model generalize better on unseen data.

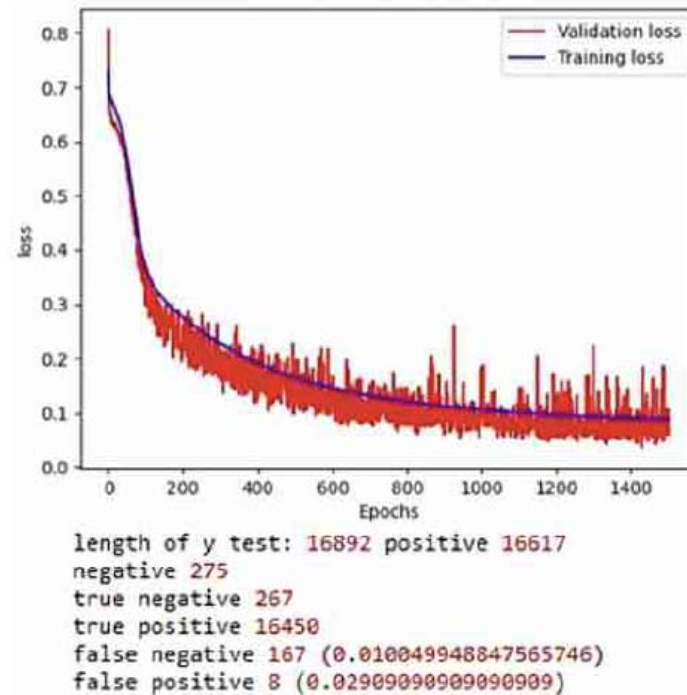


Fig. 1 Loss of M64 quality model 1

For that reason, in the next step regularization is added in the form of L2 regularization on the layers and dropout between layers. The setting of the dropout rate and L2 regularization costs can be gauged by trying different configurations and choosing those with the best performance. The goal is to fit a maximum regularization that will still allow the model to learn well. Changing the batch size to 256 and epochs to 2,000 the model starts to show a higher variance with more iterations (Fig. 2).

This can be prevented by increasing the batch size incrementally [3]. For this model, the batch size will be doubled every 500 epochs.

As shown in Fig. 3, variance could be drastically reduced in the higher epochs using an increased batch size. The rate of the false positives with 5.1% is much higher than the rate of false negatives with 0.8%. Since the objective is to reduce the rate of false positives, if necessary, at the cost of the rate of false negatives, we can alter the class weights to shift the error towards false negatives. A factor of 4 to alter the class weights showed good results for the classification rates with a rate of false positives 3.3% and false negatives of 2.2% (Fig. 4).

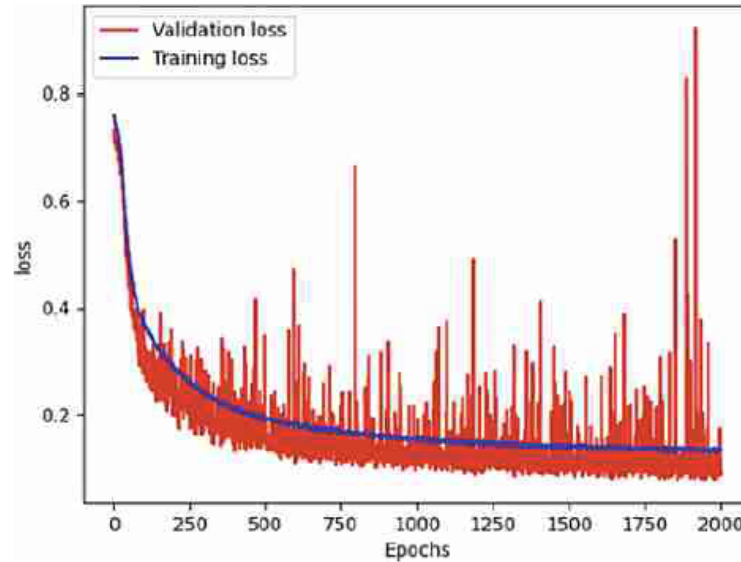


Fig. 2 Loss of M64 quality model 2


## 2.4 Parameter Configuration Optimization

The goal is to minimize energy usage and maximize the number of good quality parts. Therefore, to combine both models, the function that should be minimized is a product of the prediction of energy usage and the prediction of the shot producing a bad quality part:

$$\text{pred}(p_{\text{energy}}, p_{\text{quality}}) = \text{pred}(p_{\text{energy}}) \times (1 - \text{pred}(p_{\text{quality}}))$$

Subsequently, Hyperopt is used to find local maxima in the combined predict function. Different search room functions are used to find different local minima. Using the search room functions uniform, normal, loguniform and lognormal yields four different parameter configurations. Then each parameter configuration is analyzed using LIME. To maximize the quality classification, we pick the parameters with the highest influential on good quality. In the table, the most influential parameters are listed with their normalized values. In this case, the values are within the boundaries of 0 and 1, and the values lie in the range of previously measured values. A negative influence would contribute to a lower energy, which is the objective, so we pick those parameters to go forward. Again, the values are within the 0, 1 range and are therefore usable. Similarly, the analyzation of the parameter influences using LIME is done for every one of the four configurations found using Bayesian optimization.

Many of the parameter values do not lie within the range 0, 1 of previously measured data points. This means that those configurations are not usable, since the model has minima outside of the value range, where we cannot make assumptions



**Fig. 3** Loss of M64 quality model 3

without having sufficient data in that range. It can be found, that only the first configuration found using a uniform search room function can be proceeded with (Figs. 5 and 6).

Since the objective is to find single parameter changes that improve production instead of a full configuration set, the individual parameters need to be tested for their influence on the predictions. This can mean that some parameters, that were previously found to have a positive influence do not perform as well individually, since that performance could be dependent on the values of other variables. For this

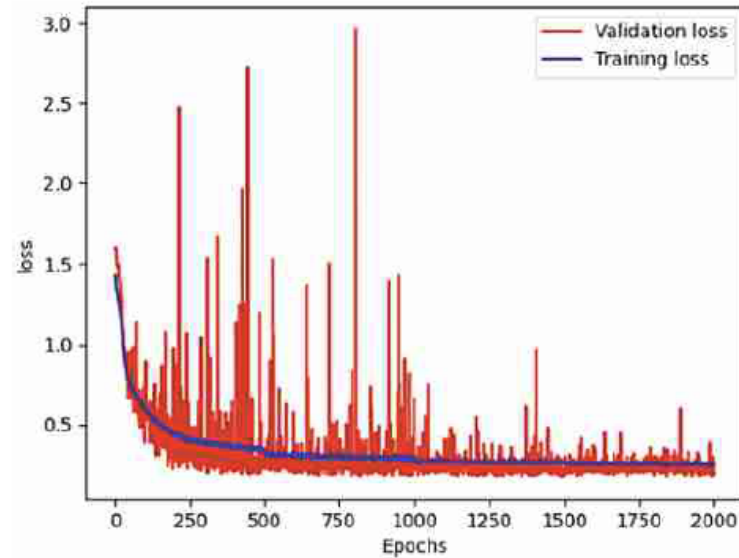


Fig. 4 Loss of M64 quality model 4



Fig. 5 LIME results for quality

reason, the parameters with the most positive influences are then tested on a sample of size 1,000. The results of this test are presented (Table 3).

Some parameters perform very well, such as *Zylinderheizzone\_2\_K1*, where both quality and energy are improved. Other parameters such as *Zylinderheizzone\_5\_K1*, a small decrease in quality would be acceptable for a large energy improvement. If the decrease in quality or energy is too large, or both quality and energy are decreased, the parameter does not give good results and is discarded. The following parameters remain: *Zylinderheizzone\_1\_K1*, *Zylinderheizzone\_2\_K1*, *Zylinderheizzone\_5\_K1*



Fig. 6 LIME results for energy

Table 3 Quality and energy improvement on sample

Parameter	Normalized value	Quality improvement (%)	Energy improvement (Wh)
Zylinderheizzone_1_K1	0.93	6.65	-4.27
Zylinderheizzone_2_K1	0.97	4.87	6.29
Zylinderheizzone_4_K1	0.31	-11.44	13.26
Zylinderheizzone_5_K1	0.15	-1.36	48.89
Umschaltvolumen_K1	0.43	-36.90	-55.65
Umschaltvolumen_K2	0.64	-5.69	32.28
Einspritzzeit_K2	0.95	-4.69	-0.17
Maximaler_Spritzdruck_K2	0.38	-19.78	41.91

and Umschaltvolumen\_K2. They are then evaluated based on how close they are to previously measured parameter and the accuracy of the predict functions around those parameters. In the following, an altered version of the standard error of the mean  $\delta_y^-$  is used to combine the number of close parameters  $N$  (within a certain radius  $r$ ) and the deviation of true parameter values from predicted values  $x_i - x_{pred}$  into a single metric:

$$\delta_y^- = \frac{\delta}{\sqrt{N}}$$

where for the standard error of mean (SEM), the standard deviation  $\delta$  is:

$$\delta(y) = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (y_i - \bar{y})^2}$$

The standard deviation measures the amount of variation of a set of values with regards to their mean. However, for this application, the aim is to find a metric for the variation of the predicted values from their true values. Therefore, the average  $y$  is exchanged for the respective predicted values  $x_{\text{pred},i}$ . The altered version of the SEM consequently uses an altered version of the standard deviation. Going forward, the altered standard error of the mean will be abbreviated ASEM.

$$\delta_y^{-*} = \frac{\delta^*}{\sqrt{N}}$$

$$\delta(y)^* = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (y_i - y_{\text{pred},i})^2}$$

This metric was implemented in a function that searches within a radius of 0.02. If there are no data points within the radius, the function returns *None*. Otherwise, it returns the number of parameters within the radius and the SEM value. As the table of SEM values shows, all the four parameter values lie in areas where the predict function is quite confident. These parameters performed well on a sample and lie confidently within previously measured values. Therefore, they are the suggested parameters (Tables 4 and 5).

These parameters are all independent variables, and it is thereby possible to set their values at the machines. These settings are then the recommended changes to improve upon the performance.

#### Model of machine M67

The optimized quality model of M67 shows a rate of 9.1% of false positives. After optimizing the loss function using Hyperopt, the resulting configurations are

**Table 4** ASEM values—quality and energy

Parameter	SEM quality	SEM energy
Zylinderheizzone_1_K1	0.0014	0.8299
Zylinderheizzone_2_K1	0.0014	0.8297
Zylinderheizzone_5_K1	0.0050	6.1288
Umschaltvolumen_K2	0.0015	0.2813

**Table 5** Recommended settings

Parameter	Normalized value	Recommended setting
Zylinderheizzone_1_K1	0.93	206.5040 °C
Zylinderheizzone_2_K1	0.97	205.4400 °C
Zylinderheizzone_5_K1	0.93	205.3000 °C
Umschaltvolumen_K2	0.64	4.4294 cm <sup>3</sup>

explained using LIME. The parameters contributing to the quality improvement or energy reduction are then tested on a sample of 1,000 data points. The results are shown in the overview below. The sample, such as *Werkzeugheizkreis\_2*, resulting in an increased energy of 60 Wh. Only the well performing parameters are selected and then, the confidence of the model is tested locally around those parameters using the SEM score. The confidence of the model around the value for *Dosierzeit\_K1* and *Zylinderheizzone\_7\_K1* is not very high and therefore these settings are discarded (Tables 6 and 7).

### Model of machine M68

The optimized quality model of M68 shows a rate of 11.3% of false positives. The energy model comes to a percentual error of 47.75%. It was not possible to train an energy model with a lower error than 47.8% due to too few data points for M68. Therefore, no recommendations are possible.

**Table 6** Quality and energy improvement on sample

Parameter	Normalized value	Quality improvement (%)	Energy improvement (Wh)
Werkzeugheizkreis_1	1.0	0.16	1.24
Massepolster_K1	1.0	0.13	7.41
Temperiergeraet_4	0.27	0.02	-0.20
Maximaler_Spritzdruck_K1	0.25	0.14	0.43
Werkzeugheizkreis_2	0.02	0.19	-60.17
Dosierzeit_K1	0.97	0.16	2.06
Einspritzzeit_K1	0.90	0.05	0.08
Temperiergeraet_3	0.96	0.05	-0.58
Umschaltvolumen_K1	0.77	-0.07	-0.18
Zylinderheizzone_7_K1	0.14	0.15	1.82

**Table 7** ASEM values of M67

Parameter	SEM quality	SEM energy
Werkzeugheizkreis_1	0.003	0.241
Massepolster_K1	0.011	0.287
Maximaler_Spritzdruck_K1	0.011	0.315
Dosierzeit_K1	None	None
Einspritzzeit_K1	0.052	0.077
Zylinderheizzone_7_K1	None	None

**Table 8** Quality and energy improvement on sample

Parameter	Normalized value	Quality improvement (%)	Energy improvement (Wh)
Zylinderheizzone_3_K2	0.42	0.16	1.24
Zylinderheizzone_4K2	0.69	0.02	-35.07
Zylinderheizzone_4_K1	0.29	0.04	0.47
Zylinderheizzone_1_K1	0.51	0.06	0.11
Massepolster_K1	0.87	-0.50	-83.54
Werkzeugheizkreis_1	0.62	-0.06	-133.09
Temperiergeraet_2	0.17	0.04	-1.52
Zylinderheizzone_5_K2	0.62	-0.01	-31.98
Werkzeugheizkreis_2	0.46	-0.05	-498.25
Umschaltvolumen_K1	0.71	-0.73	-3389.41
Zylinderheizzone_3_K1	0.39	-0.01	-0.91
Dosierzeit_K1	0.78	-0.26	2.67
Zylinderheizzone_5_K1	0.37	0.08	-4.97

**Table 9** ASEM values

Parameter	SEM quality	SEM energy
Zylinderheizzone_3_K2	None	None
Zylinderheizzone_4_K2	None	None
Zylinderheizzone_4_K1	0.003	6.073
Zylinderheizzone_1_K1	0.003	5.311

### Model of machine M69

The optimized quality model of M69 shows a rate of 4.1% of false positives. After optimizing the loss function using Hyperopt, the resulting configurations are explained using LIME. The parameters contributing to the quality improvement or energy reduction are then tested on a sample of 1,000 data points. Evidently, some parameters perform poorly on the sample, such as *Umschaltvolumen\_K1*, resulting in an increased energy of 3,389 Wh (Tables 8 and 9).

## 3 Results

To calculate the energy savings for a whole year, the number of produced parts is interpolated from the period of data acquisition lasting 112 days onto a year. The numbers can be found below [9] (Table 10).

The predicted energy savings per produced part are then multiplied with the number of produced parts each year to yield the possible energy savings according

**Table 10** Interpolated produced parts of the machines

Machine	Parts produced in total	Parts produced in a year
M64	168,917	550,488
M67	247,052	805,125
M68	86,203	280,929
M69	275,286	897,137

**Table 11** Model accuracies

Machine	Number of data points	Quality model (%)	Energy model
M64	16,892	97.70	92.38%
M67	24,706	92.23	88.73%
M68	86,203	98.70	NaN
M69	27,529	84.50	91.11%

to this model. All these recommendations are based on a model with a certain error. With a larger error comes a larger uncertainty within the predictions of the model, and with the parameter recommendations (Table 11).

#### Machine M64

The most promising parameter is *Zylinderheizzone\_5\_K1*, since with only a slight decrease in the quality prediction, it manages to reduce the energy consumption of a single shot by 48.89 Wh. This amounts to annual energy savings of 26,913 kWh. Additionally, *Zylinderheizzone\_2\_K1* only reduces the energy consumption by 6.29 Wh, however it also manages to increase quality by 4.87%. Therefore, only this parameter change is recommended and would yield 3,463 kWh in annual energy savings (Table 12).

#### Machine M67

Of those four well performing values only the independent parameters *Maximaler\_Spritzdruck\_K1* and *Werkzeugheizkreis\_1* can be recommended as parameter settings. *Massepolster* and *Einspritzzeit* can only be measured and not set at the machines. Changing the parameter settings for *Maximaler\_Spritzdruck\_K1* and

**Table 12** Quality and energy recommendation and predicted improvement

Parameter	Recommended value	Quality improvement (%)	Energy improvement (Wh)
Zylinderheizzone_1_K1	206.504 °C	6.65	-4.27
Zylinderheizzone_2_K1	205.440 °C	4.87	6.29
Zylinderheizzone_5_K1	205.300 °C	-1.36	48.89
Umschaltvolumen_K2	4.429 cm <sup>3</sup>	-5.69	32.28

**Table 13** Quality and energy recommendation and predicted improvement

Parameter	Recommended value	Quality improvement (%)	Energy improvement (Wh)
Massepolster_K1	17.052 cm <sup>3</sup>	0.13	7.14
Maximaler_Spritzdruck_K1	253.559 bar	0.14	0.43
Einspritzzeit_K1	1.503 s	0.05	0.08
Werkzeugheizkreis_1	80.000 °C	0.16	1.24

**Table 14** Quality and energy recommendation and predicted improvement

Parameter	Recommended value (°C)	Quality improvement (%)	Energy improvement (Wh)
Zylinderheizzone_1_K1	245.338	0.06	0.11
Zylinderheizzone_4_K1	244.877	0.04	0.47

*Werkzeugheizkreis\_1* would show a slight increase in quality as well as annual energy savings of 1,344 kWh (Table 13).

#### **Machine M68**

With only 8.621 data points for machine M68 it was not possible to train an energy regression model. Therefore, no recommendation can be made for this machine.

#### **Machine M69**

For machine M69 only two parameters could be found which improve results and lie within a certain range of previously measured parameters. Together they could save 520 kWh of energy annually (Table 14).

## **4 Discussion**

The described project presented an approach for finding and evaluating parameter settings of machines in a producing SME using machine learning and data analyzation. Applying this method will yield single parameter changes to optimize the energy consumption and improve the quality and evaluate the confidence of the prediction within the models. It was found that neural networks can be used to find ideal machine settings for reducing energy usage and improving the quality.

For the given dataset, the best results were yielded by the models for M64. It showed the highest model accuracies and very high energy savings for its parameter recommendations. For all machines except for M68, which could not be trained due to too few training data, the parameter configurations were optimized to reduce energy usage. According to the model, total annual energy savings of 50.000 kWh could be achieved. Since it was not possible to incorporate the camera data, no statement can be

made about quality improvement. However, for a more accurate model and to improve upon quality, the camera data should be considered as well. The actual method of saving the camera data in tabular files proved to be very inefficient and not accurate. It would be recommended to develop a script that accurately allocates the camera data to its respective machine settings and adds both into the same database table. Using this new script, enough data points would have to be collected, an estimated 20,000–30,000 per machine. Once the data is collected, the proposed method can be easily applied using the software from this project. The parameter changes found this way can then be tested practically and finally permanently applied in the machine settings.

SMEs are often still uncertain when assessing the opportunities, limits, and risks of using AI in production. Insufficient knowledge and lack of experience regarding the procedures for the introduction of suitable AI technologies in production lead to a certain restraint. Often there is a lack of resources to accelerate the use of AI in production without support. One solution can be the easy adaptability of AI applications to individual operating processes. The described ANN for resource optimization is designed to individually adapt parameter settings of the machines in the production area as well as evaluation options and to use them across industries. Many SMEs are also deterred by the multitude of AI algorithms. Use cases with AI applications should be made available to use them as instruments. A close integration of science and industry can make a significant contribution to this. In Universities could prepare and make accessible their research results on AI processes in production for SMEs. Many research institutions already have proven transfer and demonstration facilities, especially for Industry 4.0 technologies, as well as successful example applications [4]. In addition, universities can also support SMEs in an advisory capacity—starting with data collection and preparation to the use of the AI application during operation and the training of employees in the field of digital transformation.

**Acknowledgements** In cooperation with Novapax Kunststofftechnik Steiner GmbH & Co. KG, the University of Applied Sciences Berlin worked on the implementation of a prototype in the Nova [26] research project to monitor and optimize waste minimization and energy savings in an SME in the plastics industry using machine learning. This research was funded by The German Federal Environmental Foundation (Deutsche Bundesstiftung Umwelt DBU) with grant number 34589/10. Results of this research project included a bachelor's [7] and a master's thesis [9].

## References

1. Chui, M., Malhotra, S.: Notes from the AI frontier: AI adoption advances, but foundational barriers remain, San Francisco (2018)
2. Matt, D., Modrak, V., Zsifkovits, H.E. (eds.): Implementing Industry 4.0 in SMEs: concepts, Examples and Applications. Springer eBook Collection. Palgrave Macmillan, Cham, Switzerland (2021)
3. Neal, B., Mittal, S., Baratin, A., Tantia, V., Scicluna, M., Lacoste-Julien, S., Mitli-agkas, I.: A Modern take on the bias-variance tradeoff in neural networks (2018)

4. Plattform Lernende Systeme: KI-Landkarte: Nachhaltigkeit - PLS. (2022). <https://www.plattform-lerndesysteme.de/nachhaltigkeit-karte.html>. Accessed 7 June 2022
5. Ribeiro, M.T., Singh, S., Guestrin, C.: "Why should i trust you?": explaining the predictions of any classifier (2016)
6. Ribeiro, M.T., Singh, S., Guestrin, C.: Model-agnostic interpretability of machine learning (2016)
7. Risch, L.: Machine learning for increasing resource efficiency in a production SME in the automotive industry. Bachelor thesis. University of Applied Sciences HTW Berlin (2020)
8. Schmidt, M., Spieth, H., Bauer, J., Haubach, C.: 100 Betriebe für Ressourceneffizienz, vol. 1. Springer, Berlin Heidelberg, Berlin, Heidelberg (2017)
9. Scholten, J.: Machine Learning als Werkzeug zur Optimierung des CO<sub>2</sub>- und Plastik-verbrauchs bei der Produktion von thermoplastischen Kunststoffen eines Automobilzulieferers mittels Big Data Analyse. Master thesis, University of Applied Sciences HTW Berlin (2020)
10. Teerasoponpong, S., Sopadang, A.: A simulation-optimization approach for adaptive manufacturing capacity planning in small and medium-sized enterprises. *Expert Syst. Appl.* **168**, 114451 (2021). <https://doi.org/10.1016/j.eswa.2020.114451>
11. Willenbacher, M., Scholten, J., Wohlgemuth, V.: Machine learning for optimization of energy and plastic consumption in the production of thermoplastic parts in SME sustainability. **13**(12), 6800 (2021). <https://doi.org/10.3390/su13126800>

### 3: Rebound Effects in the Use of Rare Earth Metals in ICT

## Rebound Effects in the Use of Rare Earth Metals in ICT



Martina Willenbacher<sup>1,2\*</sup> and Volker Wohlgenuth<sup>2</sup>

<sup>1</sup>Institute of Environmental Communication, Leuphana University Lüneburg, Germany

<sup>2</sup>School of Engineering - Technology and Life, Germany, University of Applied Sciences HTW Berlin

Submission: February 28, 2022; Published: March 11, 2022

\*Corresponding author: Martina Willenbacher, Leuphana University Lüneburg, Institute of Environmental Communication, Universitätsallee 1, 21335 Lüneburg, Germany & University of Applied Sciences HTW Berlin, School of Engineering - Technology and Life, Treskowallee 8, 10318 Berlin

#### Abstract

This work looks at the rebound effects associated with digitalization of the use of rare earth metals in terms of environmental sustainability with a focus on the life cycle of REE in its technological applications. There is no doubt that digitization offers numerous advantages for industry and society. These primarily include improving efficiency and performance, as well as optimizing the susceptibility to disruption of production and business processes through automation, the consistent availability of information in connection with rapid knowledge transfer. This also results in lower process costs and short reaction times to problems within the value chain. Employees can be used more flexibly due to mobile work. The most important topics of digitization include artificial intelligence, robotics, the Internet of Things, cloud computing and autonomous driving. However, digitization also has environmental disadvantages. These include, above all, an increasing demand for raw materials and its cost-effective procurement in countries with low environmental and social standards instead of a sustainable circular economy, which is financially and industrially more complex for manufacturers. For this purpose, a model calculation of ICT devices in the consumer sector is carried out within the scope of this work and the resulting electronic waste is determined.

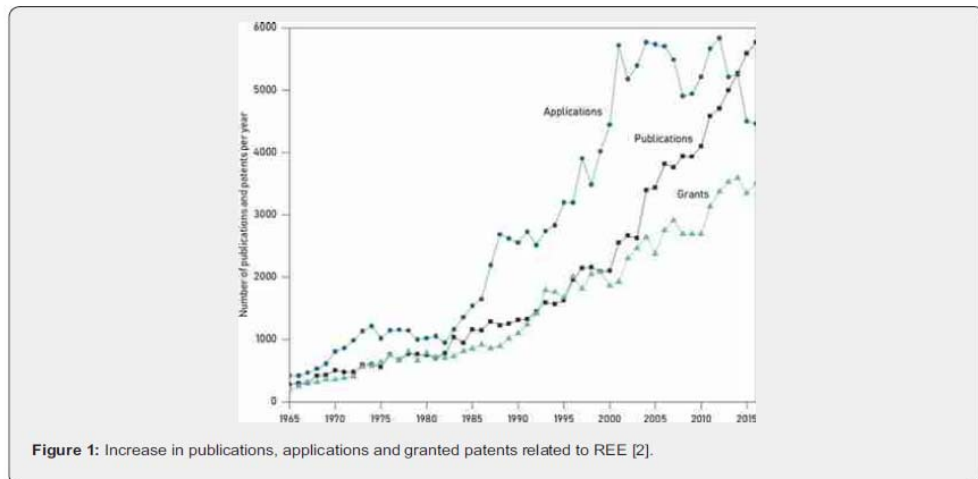
**Keywords:** Rare earth metals; Digitalization; ICT; Rebound effect; Sustainability

#### Introduction

Due to their special physical and chemical properties, rare earth metals are one of the most important raw materials to produce electronic applications in various industries and thus play a decisive role in technological progress. The term „rare“ in connection with rare earths is often used misleadingly and does not refer to the real frequency of their occurrence. At the time of their discovery and in the following decades, scientists assumed that these elements occur only in very small quantities in a few places. However, they are not rarer than, for example, copper and more common in nature than lead [1]. Another explanation is also the meaning of „rare“ in the sense of „strange“ or „extraordinary“. The term „earth“ is the term taken from Latin for „oxides“. Even though this term is often assigned to all critical raw materials, „rare earths“ is clearly defined in the terminology of chemistry. Rare earth metals include 17 chemically similar elements – scandium, yttrium, and the group of lanthanides. Except for promethium, a fission product of uranium, these metals occur socialized in nature due to their identical reaction behavior. Therefore, in the past, the biggest challenge was to isolate and analyze them. Only

with the technological advancement of analytics such as mass and atomic emission spectrometry was it possible to identify these elements. Due to their special physical properties, they are used in a variety of technical applications. Although they are very similar in their chemical and physical properties, each of the rare earth elements has its own specific disposition. Due to their wide range of applications, REE are also regarded as a driver of innovation. This is evident in the rapid increase in publications, applications, and patents since the beginning of the 21st century.

Figure 1 publications related to REE shown in Figure 1 also results in an ever-increasing demand for rare earth metals. At the same time, economic growth through technological progress also requires a higher demand for resources. A decisive rebound effect can be observed: the more economical a system is, the more purchasing power and innovation potential there is. This in turn increases the consumption of resources. Companies also tend to obtain production factors as cheaply as possible. As a result, raw materials important for technologies are often sourced from countries with low social and environmental standards.



### Rebound Effects

In 1865, the English economist William Stanley Jevons argued in his book „The Coal Question“ that the more economical consumption of coal did not lead to lower consumption, but caused exactly the opposite [3]. This gave rise to the so-called Jevons paradox, which describes the connection between the increase in energy efficiency and the increase in demand [3]. Efficiency gains are thus compensated [4], because efficiency gains also lead to an increase in the production of goods. Khazzoom went a step further in his 1980 article in the „Energy Journal“ and described that an increase in demand due to energy savings still exceeds the demand in its initial value [5]. This theorem is also known as backfire. This is illustrated, for example, by the study by Fouquet and Pearson, which shows that with the increase in more efficient light sources due to new technologies, total lighting consumption in the United Kingdom increased 25,000 times from 1800 to 2000 [6]. Leonard Brookes made similar observations, but made the connection between energy prices, gross domestic product, and energy demand. He found that an increase in energy prices would not lead to lower consumption [7]. This resulted in the Khazzoom-Brookes Postulate, which describes a rebound effect of < 100% due to additional demand. Even today, more energy- and resource-efficient production often leads to higher demand. Sorrell defined the rebound effect as unintentional increased consumption because of efficiency gains [8]. In the appraisals prepared by Madlener and Alcott for the Enquete Commission of the German Bundestag, they defined rebound as a theoretical percentage amount of possible savings, starting with a technical increase in efficiency. They further describe that these assumptions are only theoretical, since in the reality the system is expanding. The increase in technical efficiency

makes it possible to increase the population, goods, and services. According to Madlener and Alcott, the rebound effect refers to the increased consumption of resource inputs, which (1) follows these efficiency increases and (2) is somehow caused or at least made possible by them [9]. The amount of the rebound effect is the percentage of the savings potential of an efficiency-enhancing measure or technology, which is compensated by the increase in demand [10]. The literature distinguishes between direct, indirect and intersectoral rebound effects [8]. In the case of direct rebound effects, there is an increased demand for the same good or service that is related to the increase in efficiency. Intersectoral rebound effects result in increased demand for an alternative good or service. Macroeconomic rebound effects are difficult to quantify microeconomically. They relate to entire economic sectors or the entire economy. In the field of digitization, the energy requirement for the operation of data centers but also for the development of artificial intelligence applications is particularly crucial. This results from hardware-intensive training and test runs of the algorithms [11]. It can also be assumed that energy consumption will continue to increase in the future due to the increasing use of AI applications [12]. In this work, however, the production-side [3] rebound effect in times of digitization about the use of rare earth metals should be in the foreground.

### Rare Earth Elements

#### Physical/chemical basics of rare earth metals

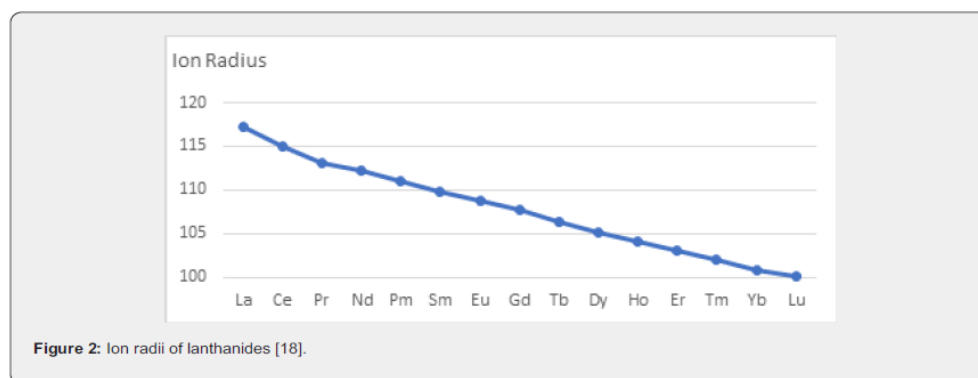
Rare Earth Elements (REE) include the lanthanides of the 6th group of the periodic system and scandium and yttrium [13] of the 3rd subgroup. A total of 17 elements, which are divided into heavy and light elements depending on their electron configuration, are therefore [14] counted among the rare earth metals (Table 1).

**Table 1:** Rare earth metals with the ion radius in the 3rd oxidation state [15].

REE	Symbol	Ordinal Number	Ionenradius Ln3+ (pm)
Scandium	Sc	21	88,5
Yttrium	Y	39	104
Lanthanum	La	57	117,2
Cerium	Ce	58	115
Praseodymium	Pr	59	113
Neodymium	Nd	60	112,3
Promethium	Pm	61	111
Samarium	Sm	62	109,8
Europium	Eu	63	108,7
Gadolinium	Gd	64	107,8
Terbium	Tb	65	106,3
Dysprosium	Dy	66	105,2
Holmium	Ho	67	104,1
Erbium	Er	68	103
Thulium	Tm	69	102
Ytterbium	Yb	70	100,8
Lutetium	Lu	71	100,1

Lanthanides have a very similar chemical behavior and occur together in nature. Separating them from each other was almost impossible for many years [13]. Scandium and yttrium have been counted among the rare earth metals by IUPAC due to their strong similarities to the lanthanoids [1]. The reason for the similarity is the special structure of the electron configuration. In all REE, the electron shell is equally occupied with 5p6s2. The distinction of

the elements is only created by filling the f-orbital. However, the f-orbital has no effect on the chemical reactions [16]. This growing nuclear charge and atomic mass causes a decrease in the ion radii of the lanthanides (lanthanide contraction), [17] which makes efficient extraction of the REE difficult. Due to the lanthanide contraction, the nuclear charge is poorly shielded and causes a stronger attraction of the 5p and 6s ions (Figure 2).



REE form predominantly positively charged ionic bonds, which are very stable and poorly soluble [19]. In connection with lanthanide contraction and ion radii, the differences in basicity are an important property for the separation of REE. Depending

on their ion radii, the basicity of lanthanum decreases to lutetium. Due to their paramagnetic properties, REE are particularly suitable for use in permanent magnets and storage media. However, paramagnetic properties also play an important role in

## International Journal of Environmental Sciences & Natural Resources

recycling. Paramagnetism describes elements that do not have a measurable magnetic moment without an external magnetic field. This results from unpaired electrons and the only partially filled f-shell of the electron configuration of the atom, which realign themselves by an external magnetic field. Due to this property, REE can be magnetized very well. REE have line-rich and sharp absorption bands [20]. The width of the frequency interval is in the range of some 100 to about 10GHz. These luminescence properties also result from the lanthanide concentration and the associated poorer shielding of the nuclear charge, resulting in the relationship between frequency and wave number [21]. Luminescence properties are particularly crucial for the area of security documents, in plasma displays, LEDs and lasers. For the detection of rare earth metals, the most common method today is ICP atomic emission spectrometry. Hot plasma is injected into the samples. These ionize and are stimulated [17]. When falling back from the excited to the ground state, the atoms release energy in the form of light in the wavelength typical of each element [22]. However, this process is very costly. Therefore, research is increasingly being carried out on biochemical processes to

establish more economical separation processes, especially in the field of recycling.

### Occurrence

The term „rare“ and „earth“ in connection with these metals is misleading and historical. At the time of its discovery, only the site of Ytterby in Sweden was known [23]. These elements were obtained only as oxides from certain minerals. REE do not occur in nature individually but oxidized and socialized in over 200 known minerals [24]. The main minerals for the extraction of REE are allanite (cerium, lanthanum, neodymium, yttrium), monazite (lanthanum, cerium, samarium, gadolinium, praseodymium, yttrium, thorium), bastnaesite (cerium, lanthanum, neodymium, yttrium), xenotime (yttrium, dysprosium, ytterbium, erbium) [17] and thortveitite (scandium) [25]. Here, too, Harkins' rule applies, which states that elements with an even atomic number occur more frequently in nature than those with an odd atomic number [26]. Only the unstable promethium occurs in nature usually only as a product of spontaneous fission with uranium and is therefore produced in the laboratory (Figure 3).

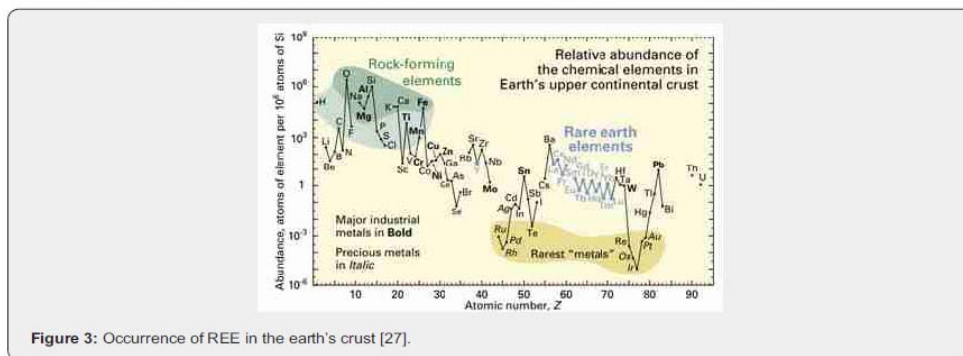


Figure 3: Occurrence of REE in the earth's crust [27].

Until the 40s of the last century, India and Brazil were the main producers of rare earth metals. From the mid-1960s to the early 1990s, the U.S. was the largest producer of REE [23]. Their mining site was mainly located on Mountain Pass in southeastern California. Since the 1980s, REE's economically viable deposits have been located primarily in China, Canada, Australia, USA, Brazil, India and Russia. The largest deposits are located in Bayan Obo, Mongolia [28]. Global reserves are estimated at 130 million tons [24] and global resources at 308 million tons [29]. The U.S. Geology Survey estimates the availability of reserves for 1100 years and of resources for 2480 years [29]. The difference between resources and reserves is that reserves are raw material deposits that are reliably detected in the earth's crust and can be mined by known technical means, while resources are suspected based on geological conditions and cannot be mined with known technologies [30]. REE resources are reported as rare earth oxides (REO). Thus, REE deposits are measured in relation to the amount

of recoverable REO. It can be assumed that with a high REO content of the deposit, more expensive mining technologies often must be used and are therefore not necessarily more economically viable than the low REO-indicated mines (Figure 4).

At over 90%, China has the highest share of world production. The most economically significant deposit is Bayan Obo in Mongolia with an iron ore deposit of more than one billion tons and a REE grade of 3-5.4%. Bayan Obo is followed by Maoniuping in Sichuan will be followed with reserves of 62.3 million tons of ore and a REE grade of 2.89% [31]. The economic availability of REE is therefore mainly dependent on the world market leader China. In addition to political instruments such as pricing and government-determined export quotas and export restrictions, there is also a lack of sustainability measures. In addition to China, the main suppliers include the USA with the Mountain Pass deposit with 90 million tons of iron ore (REE share 5%) [32] as well as Brazil and Russia (Table 2).

04

How to cite this article: Willenbacher, M., Wohlgemuth, V. Rebound Effects in the Use of Rare Earth Metals in ICT. Int J Environ Sci Nat Res. 2022; 30(1): 556277. DOI: 10.19080/IJESNR.2022.30.556277




Figure 4: Reserves of REE 2021 [29].

Table 2: Main applications of REE [17,33].

Application	REE
Screens, picture tubes	Y, Ce, Sm, Eu, Gd, Tb, Tm, Lu
Illuminants	Sc, Y, La, Pm, I, Tb, Ho, Lu
Laser technologies	Sc, Nd, Sm, Dy, Ho, Er, Tm, Yb, Lu
Magnets	Pr, Nd, Sm, Dy, Ho, Tb
Magnetic data storage	Sc, Gd, Tb, Dy, Nd, Pr
Doping	Dy, Ce, Eu
Semiconductor	Tb, Lu
Drive technologies	Y, Nd, Sm, Tb, Eu
Nuclear power	Y, Ce, Sm, Eu, Gd, Dy, Ho, Er
Spectrometry	Y
Fuel cells	Y
Medical technologies	Y, Sm, Nd, Pr, Eu, Gd, Dy, Tb, Tm, Yb, Lu
Pharmacology	La, Ce, Eu, Yb
Batteries, rechargeable batteries	La, Pm
Glass industry	La, Ce, Pr, Nd, Sm, Ho, Tm
Condensers	La, Dy
Aerospace	Ce, Pr, Pm
High performance electrodes	Ce
UV-Filter	Ce
Catalysts	Ce, La, Pr, Nd, Yb
Steel and metal processing	Ce, Yb
Material and material testing technology	Ce, Tb, Dy, Tm
Insulators	Ce, Tb
Pyrotechnics	Ce
Clothing industry	Ce
Microwaves	Gd, Tm
Kyro cooler	Er
Fiber optics	Y, Eu, Tb, Er
Bank notes (Lorenz & Bertau, 2019)	Eu, Tb

### Main applications

The areas of application of REE are diverse. The following table gives a rough overview of the main applications of the REE.

REE play an important role in the use of ceramics. These are present in almost all technical devices in actuators, sensors, resistors, and insulators. In view of the ever-increasing technologization, increasing demand for REE is to be expected. The field of application with the highest demand are permanent magnets, which are used in numerous electronic devices. A market analysis by Adamas Intelligence [34] came to the conclusion that demand is expected to rise steadily by 9.7% by 2030. Therefore, it can be assumed that as technology progresses, a shortage of raw materials will occur about REE, as these elements are not a

renewable resource, and their availability is limited.

### Environmental Aspects

#### Funding and processing

The degradation of REE is associated with considerable environmental and health damages, as energy- and cost-intensive separation processes and intensive chemical post-treatment are necessary [30]. The extraction of REE can be divided into 4 process steps: mining of the ores from the mine, washing of the ores, separation of the REE from the concentrates, as well as the production of metals and alloys [23]. Depending on the deposit, ore mining takes place in open pit mining, underground mining, and leach mining (Table 3).

Table 3: Degradation methods of REE [30].

Experience	Description	Advantage	Disadvantage
Opencast mining	<ul style="list-style-type: none"> <li>· Mining in open pits with deposits &lt; 100 m below the earth's surface</li> <li>· Conveying with bucket wheel excavators</li> </ul>	<ul style="list-style-type: none"> <li>· No artificial underground tunnels and shafts necessary</li> </ul>	<ul style="list-style-type: none"> <li>· Large amounts of overburden</li> </ul>
Underground mining	<ul style="list-style-type: none"> <li>· Mining by means of underground tunnels and shafts at occurrences &gt; 100 below the earth's surface</li> </ul>	<ul style="list-style-type: none"> <li>· More precise development of the deposits than in opencast mining · Less overburden</li> </ul>	<ul style="list-style-type: none"> <li>· Damage caused by crime and subsidence</li> <li>· Risk of lowering the groundwater level and pollution of water bodies</li> </ul>
In-Situ-Mining	<ul style="list-style-type: none"> <li>· Mineral development in ion-based clay deposits</li> <li>· Drilling and dislocation with chemicals to convert REE into their sulfates</li> </ul>	<ul style="list-style-type: none"> <li>· No movement of large amounts of rock · Also suitable for small deposits · Technically undemanding</li> </ul>	<ul style="list-style-type: none"> <li>· Frequently illegal mining without environmental protection measures · Contamination of rock layers carrying drinking water</li> </ul>
Deep-sea mining (no mining technologies available yet)	<ul style="list-style-type: none"> <li>· Mining from manganese nodules in the deep sea</li> </ul>		<ul style="list-style-type: none"> <li>· Immense environmental damages</li> </ul>

In the next step, the ore washing, the ores are separated from the adhering rock by leaching with chemicals or by mechanical digestion (dry processing). They are then crushed, ground, sieved and slurred with water. Then the separation of the ores is carried out by flotation with a variety of chemicals and separated according to density differences or magnetic fields conferring to magnetic properties [23]. The REE must be extracted from the minerals obtained in this way. This is done by various chemical processes, which must be adapted to the respective mineral concentrate. The separation then takes place by means of ion exchange chromatography and solvent extraction [30]. These processes consist of several complex process steps and require a high degree of technical know-how. To produce a metal from the oxide, the extremely energy-intensive process of melt flow electrolysis is used. Melt flow electrolysis uses a salt mixture as an electrolyte and thus increases the solubility of the REE. To eliminate further non-metallic impurities, the REE are then refined or distilled using various processes (Figure 5) [23].

### Environmental impact of the extraction process of REE

The entire extraction process is characterized by a high intensity of the use of water and energy. Due to China's dominance

in mining and processing, well-founded data is scarce. Even the government-mandated volume targets for exports cannot curb this problem. In addition, China has illegal mines to trade REE on the black market [77]. Due to the mining processes, the creation of overburden leads to increased land consumption. Massive ecological damage results from the strong intervention in the soil structure. The technical machines for conveying the ores generate dust and emissions. Large quantities of hazardous waste and residues such as the release of radioactive elements and heavy metals as well as silicates and leaching chemicals are also generated during in-situ mining. These blind rocks are stored on heaps, which leads to the spread of dusts of toxic substances by wind and debris in wastelands and groundwater. The heaps are surrounded by dams. If these dams break due to weather influences, the toxic chemicals enter the surrounding areas and damage nature and the environment in the long term. It is estimated that in China, the refining of one ton of REE oxide produces 63,000m<sup>3</sup> of sulphuric and hydrofluoric acid residues and 1.4 tons of radioactive waste [36]. Another possibility of mining is seen in the deep sea. Manganese nodules at a depth of about 3000-6000m have cobalt, copper, nickel iron and REE in addition to manganese. These manganese nodules are formed by

erosion or from hydrothermal vents of volcanically active marine areas [37]. They grow dia- or hydro genetically by attaching metal ions. Since the manganese nodules grow very slowly (10mm/million years), they can only form where constant environmental conditions prevail over long periods of time [37]. So far, however,

there are no proven technologies for the extraction of REE from the deep sea. Mining licenses are also not yet available due to a lack of legal framework conditions. In the mining methods currently under discussion, the seabed surface with its fauna is removed. This damage to the seabed is lasting for many centuries [38].

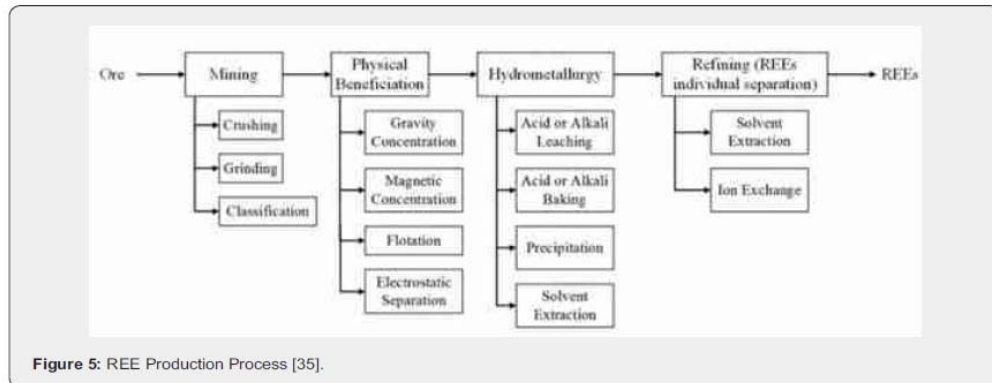


Figure 5: REE Production Process [35].

In the mining areas of the REE, these are also deposited to a particularly high degree in the human body. This applies in particular to the miners but also to the residents in the vicinity of the mine [39], as the occupational safety measures are inadequate in most areas. Little is currently known about the effects of rare earths on bioaccumulation. However, in affected mining areas, an increased number of leukemia cases and birth defects are reported

[40]. However, these substances also enter the organism through the penetration of REE into environmental compartments, both during production and disposal. The highest concentrations in the human body are accounted for by the element's cerium, neodymium and lanthanum [41]. At present, there are few studies on the biological effects of REE exposures. This area requires further, detailed research [42].

### Recycling and disposal

Table 4: REE flows (in %) for recycling [46,47].

REE	Pre-Consumer Recycling		Post-Consumer Recycling	
	Production residues (magnetic waste, slag, FCC process) (%)	Phosphors (LED, LCD, plasma screens, optical glass) (%)	Neodymium-iron-boron magnets (hard disks, computer peripherals, mobile phones) (%)	Batteries (%)
Scandium	0,0064			
Yttrium	0,015	53,55		0,71
Lanthanum	1,84	40,8		22,58
Cerium	0,2	1,8		8,8
Praseodymium	3,5		22,87	4,69
Neodymium	27		171,31	7,13
Samarium	0,0008		39,2	6,2
Europium	0,0002	3,98		
Gadolinium	0,0008	3,99		
Terbium	0,14	1	0,3	
Dysprosium	3,15		46,29	
Erbium	0,0013			
Ytterbium	0,0003			

Despite the great importance of REE in ICT and industries of other high technologies as well as the relatively high potential for recycling possibilities, only about 1% [43] – 2% [44] are recycled from end products. This is largely due to the low profitability of using expensive and technically demanding recycling processes compared to the moderate raw material prices of the import [30]. Particularly affected by the fall in prices are the elements cerium and yttrium, which have lost more than 90% of their value since 2011 [45]. Furthermore, recycling is difficult due to the very low occurrence of REE in the end products and the high degree of dilution in the components as well as their dissipative distribution. The conventional recycling methods of hydrometallurgical and wet chemical methods are inefficient and uneconomical due to low market prices. In order to achieve the desired product quality, hydrometallurgical processes are usually used [46]. These process steps are carried out by ore washing and the use of large amounts of acid. So far, only the recycling of REE is only commercialized from phosphors, magnets, and batteries [29]. An overview of this is given in Table 4. In the case of recycling processes, a distinction is made between pre- and post-consumer recycling. Pre-consumer recycling refers to the recycling of REE from production residues, while post-consumer recycling refers to the recycling of the end device (Table 4).

For example, in 2015, only an average of 5% of e-waste generated in the EU was recycled. No recycling cycle is known for Scandium [48]. However, a controlled circular economy reduces the serious environmental impact of mining and production. In addition, the important resources of the REE are irretrievably lost without a reappraisal [49]. Furthermore, the dependence on China as the main producer will be weakened. Important know-how in the field of REE processing can also be built up [50]. The processes of recycling REE are mechanical processing, thermal extraction (pyrometallurgy) as well as wet chemical extraction (hydrometallurgy) and reduction of REE alloy. In practice, a combination of the pyro- and hydrometallurgical process is often used [49]. However, in addition to their low economic efficiency, these processes are also energy- and resource-intensive with too low economic efficiency and high processing costs. However, novel and more efficient recycling approaches have recently been developed. In the REEgain project [51], researchers are developing a method based on bioaccumulation with algae on which the REE of the raw material is attached.

As part of the EU project RECUMETAL, a pilot plant for the recovery of indium, yttrium, and other valuable metals from discarded flat screens was designed and developed [52]. A team of researchers from the University of Pennsylvania developed a tripodal nitroxide ligand to separate neodymium and dysprosium from e-waste. This method differs from the usual energy-intensive industrial solvent extraction in that it can be performed at room temperature and with standard laboratory equipment [53]. A fluorescence-based sensor developed by researchers at Penn State University that detects the lanthanide-binding protein

Lanmodulin (LanM) in bacteria enables the detection of tiny amounts of REE in samples [54]. This technology is useful for cost-effectively quantifying REE in environmental and industrial samples, because today's gold standard for detecting REE is ICP mass spectrometry. Due to the use of special, very sensitive instruments, this process is very cost-intensive [55] and therefore uneconomical for most manufacturers of electronic components. Furthermore, the research showed that the rare earth metals with atomic numbers 57 to 64 enter the cytosol of the cells of the bacterium. The reasons for this high intake selectivity are not yet known. In further research, the extraction of REE by LanM was applied to pre-combustion coal and electronic waste. After only a single purely aqueous step, a quantitative and selective recovery of the REEs from all initially existing non-REEs (Li, Na, Mg, Ca, Sr, Al, Si, Mn, Fe, Co, Ni, Cu, Zn and U) was achieved, which demonstrates the universal selectivity of LanM for REEs against non-REEs and its potential application even for industrial substandard sources that are currently underutilized, demonstrated [56]. The EU project SCALE developed a process to extract scandium from red sludge from bauxite residues of the aluminium industry using various crystallisation techniques. For this purpose, scandium ions are leached with reagents to form a liquid solution, which is then upgraded by an ion exchange technology newly developed in the project. No waste is generated. Iron oxide concentration as a solid by-product can be used for pig raw iron production. Scandium is extracted from acidic waste from the titanium (IV) oxide pigment industry using a novel nanofiltration technology. Based on the recovery processes, the SCALE project also developed technologies to produce metallic scandium in an environmentally friendly manner [57]. The r4-Lan-Tex project developed a novel technology for the selective separation of the lanthanum ions via fiber-fixed bonds to polyelectrolytes from wastewater from FCC catalyst production [58]. The EU project SepSELSA became a reprocessing and recovery process of REE based on solid chlorination. With the use of diffusion dialysis [59], about 25 tons of production waste could be processed and REE returned to the production cycle as part of the project. The innovation of this process is the isolation of the metals in pure form without the countless separation stages of conventional processing [45]. The BioKollekt team [60] is researching a separation process for the economical recycling of complex material mixtures with a special focus on the finest particles with the help of specially developed peptides that specifically bind particles in solutions. For this purpose, these are firmly anchored to a carrier material with certain chemical and physical properties, so that the target materials are selectively isolated from the complex material mixture. The matching peptides are produced using the phage surface display method [61] developed by chemistry Nobel Laureate George P. Smith. With classic particle separation methods, the chemical collectors stick to the target particles and cannot be recycled. All other collectors, including the residual materials, end up on the stockpiles. Biocollectors, on the other

hand, are recyclable and can be used again and again in separation processes. The target substances are dissolved by the biocollector, for example, by changing the pH value in the solution. The magnetic carriers, like the peptides, are fully biodegradable [60].

#### Substitution

Another way to reduce the resource consumption of REE is to use alternative materials and processes. However, the success of material substitution in relation to REE to date is very limited, as many of the main applications of ICT are not currently substitutable. These include above all optical cables, miniaturized permanent magnets, ferrites and components made of laser devices, magneto-optical storage materials, monitors and displays, pn LEDs, compact disks and cooling devices based on the magnetocaloric principle [23]. A study by Yale University's Center for Industrial Ecology found that for 62 different metals, the potential substitutes for their main applications are either inadequate or currently non-existent. In addition, for not one of the 62 metals examined, exemplary substitutes are available for all important applications [62]. Since the REE uses their specific physical properties, the substitution of one REE by another REE is usually required. For example, researchers at Iowa State University's U.S. Department of Energy have developed a method for replacing dysprosium with the commonly occurring cerium in permanent magnets [63]. However, research approaches in the field of magnets show that, for example, with iron, substituted in lithium nitride ( $Li_2(Li_1 - Fe_x)N$ ), behaves like a rare earth metal in relation to its magnetic anisotropy [64]. However, since REE are degraded together, the environmentally friendly effect is small. On the other hand, technological substitution, in which manufacturing processes are improved, offers more potential. The Fraunhofer Institute developed the so-called Net-Shape method to produce high-performance permanent magnets, in which post-processing can be dispensed with and thus the consumption of dysprosium and neodymium is reduced by 15% [65]. Siemens developed

a process for the production of REE-free permanent magnets based on an iron-cobalt compound with magnetic nanostructures [66]. Other approaches include the development of new rotor structures with increased demagnetization resistance and higher magnetic cooling performance while reducing the dysprosium and terbium content in NdFeB magnets [67]. In the field of hard disks, a functional substitution was achieved by the development of SSD, in which not the magnetic effect, but the atomic spin is used for data storage. Also, the use of OLEDs instead of energy-saving lamps replaces part of the REE with organic light-emitting diodes. The binding layer does not require ANY REE, only Europium is still used in the emitting layer. However, from today's perspective, no disruption from LEDs to OLEDs is to be expected, as they are smaller than conventional light-emitting diodes due to their size and burn time. The main applications for OLEDs are currently small area displays such as smartphones.

#### Use of ICT in the Consumer Sector

Information and communication technologies are now an indispensable part of society and the economy. In addition to broadband use, smart devices are also becoming increasingly popular. The most common devices are smartphones with a share of 72.5% of Germans [68] followed by headphones (71%) [69], TVs (44%) [70], game consoles (39.7%) [69], radios (35.8%) [71], wearables (33%), [69] smart speakers and e-book readers with 26% each [69], laptops (23.5%) [72], desktop desktop PCs (22.3%), vacuum cleaner, lawn mower or window cleaning robots (18%) [69], augmented reality devices (14%) [69] and tablets with 9.9% [69]. With several households of 41.5 million with a total of 83.2 million household members almost every second German citizen will own [72] at least one TV set in 2020. This results in a total number of ICT devices of approx. 364.8 million in Germany. Smart home applications for energy management, building security, home automation and health were not considered (Figure 6).




Figure 6: Number of ICT devices in Germany in 2020.

**Model Calculation of ICT Devices Worldwide**

In the following, these data are extrapolated to the countries with a very high Human Development Index (HDI). The HDI is

calculated from life expectancy, school education in combination with the expected total education and gross national income per inhabitant in USD [73]. This results in values between 0 and 1 for the following classification (Table 5 & Figure 7):




Figure 7: Human Development Index ( $\geq 0.8$ ).

Table 5: Development categories [73].

HDI-Range	Category
$\geq 0,8$	Countries with very high levels of development
$\geq 0,7$	Countries with high human development
$\geq 0,55$	Countries with medium human development
$< 0.549$	Countries with low human development

A total of 66 countries were able to achieve an HDI  $\geq 0.8$  [73]. When calculating the extrapolation, it is assumed that the ICT equipment of citizens in the individual countries is fundamentally

similar. These countries have a total population of 1.57 billion people [74]. This results in an assumed number of ICT devices of 7 billion (Figure 8).

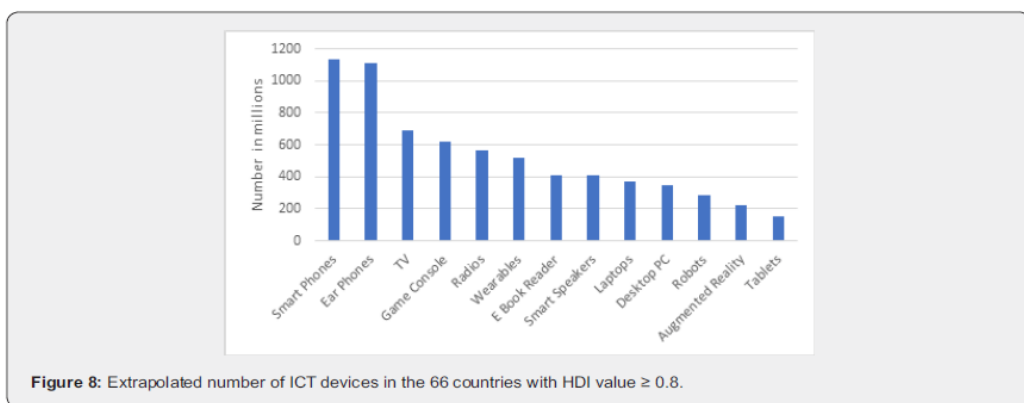
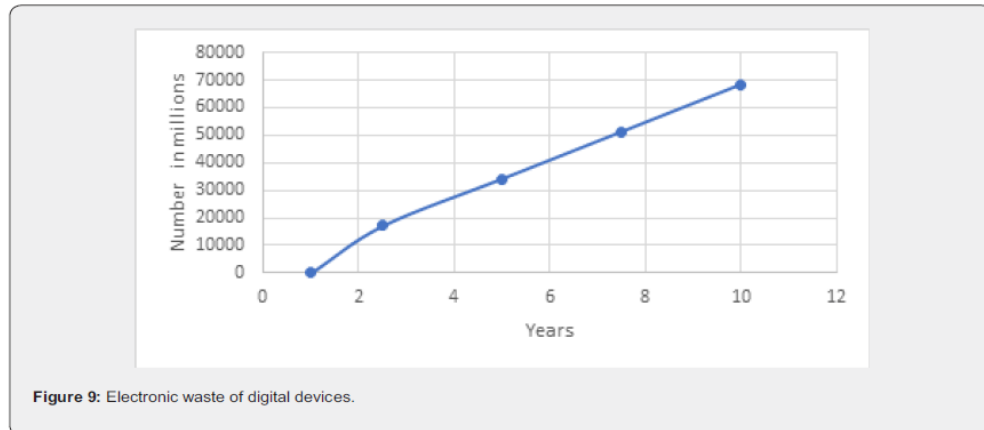


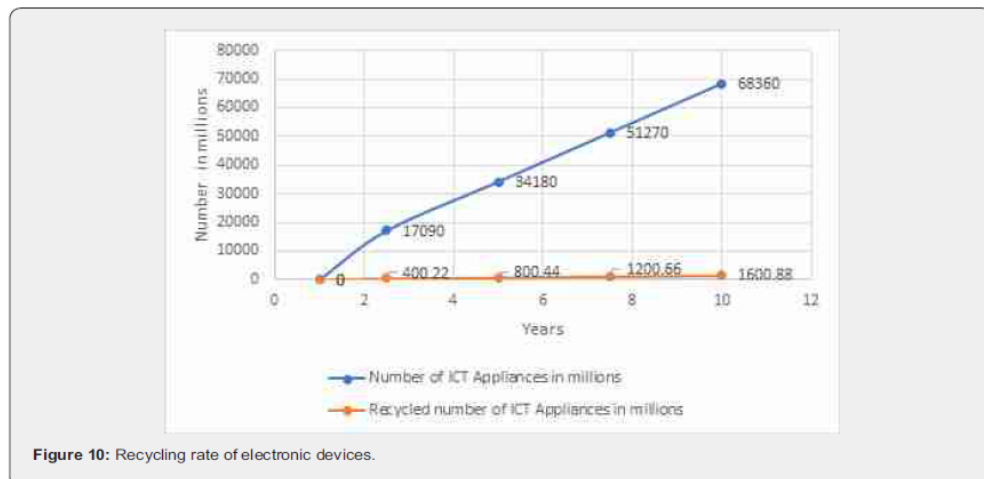
Figure 8: Extrapolated number of ICT devices in the 66 countries with HDI value  $\geq 0.8$ .

International Journal of Environmental Sciences & Natural Resources

Considering the short service life of ICT devices between devices, the amount of electronic waste is immense. After 10 years about 2.5 years for smartphones and 5 years for other digital this amounts to approximately 68 billion ICT devices (Figure 9).



Assuming a recycling rate of 5% within the EU and 1.5% in other countries [75], the total amount of e-waste is 67 billion unrecycled e-devices (Figure 10).



Discussion

There is no question that digitization has a decisive influence on sustainability in some areas, but in its entirety leads to ecological problems in other areas. Ecological rebound effects also occur in relation to consumer behavior in online retail. The main drivers for this are personalized advertising and constant availability of products, even if logistics and delivery conditions are more predictable and thus more optimizable using technology. On the

other hand, digitization enables simpler and more targeted reuse of products, for example through sharing models, second-hand platforms, and sharing platforms. More and more manufacturing companies are using intelligent software applications to optimize their material and energy flows. Profitable waste recycling in the context of circular economy can be technologically realized in the form of virtual marketplaces for the reuse of waste by other companies across industries and regions. Intelligent circular economy with automated process optimization enables the careful

use of resources over the entire life cycle. However, these methods only make sense if the use of resource efficiency is also reflected in consumer behavior, and this results in a longer use of end devices. This, in turn, requires a business model oriented towards long-term use by the companies. A combination of the production of high-quality goods with user-friendly services (maintenance, repair) would be conceivable. Furthermore, more investment should be made in the commercialization of mining and recycling processes of rare earth metals. The development of innovative processes for the extraction and recycling of REE during mining, physical processing, refining, pyro- and hydrometallurgical processes require more comprehensive political support. Novel processes offer the potential for commercialization and create a basis for reducing dependence on China's existing market leadership. The material substitution of the REE is more difficult. Rare earth metals are extracted and mined together. About this phase of its life cycle, there are no differences in the environmental impact of substitution by another REE. Elements outside the family of REE offer only inadequate alternatives [62]. More promising at the present time are technological substitutions such as the development of innovative manufacturing processes. High savings potential can also be found in the recovery of rare earths from waste products. For comprehensive recycling, however, there are hardly any processes that are economical for companies in terms of effort and cost recovery. In particular, the low raw material prices make recycling processes unattractive for companies. Recycling possibilities consist in the separation of rare earths from waste magnets and fluorescent tubes by solid chlorination [45]. REE have only been used in technical applications for about 20 years. The effects of REE on living organisms have therefore not yet been fully investigated. The current state of research assumes that there is no toxicity to humans [23]. However, REE with their compounds have only been released into the environment for some time through recycling processes. Long-term studies are not yet available. If a society and its economic system depend on growth, there will also be rebound effects. In combination with an efficient circular economy and conscious consumer behavior, the effects of rebound effects can potentially be reduced. Innovative technologies such as AI, if targeted and used, can make meaningful contributions to greater sustainability. More digitization does not necessarily lead to more efficiency [76]. As a result, it can be said that the existing resources of rare earth metals must be used optimally and sparingly. Investments in research to develop ecological and economic recycling and substitution processes are needed, as are environmentally friendly processes for the degradation and separation of REE.

## References

1. Connelly NG, Damhus T, Hartshorn RM, Hutton AT (2005) Nomenclature of Inorganic Chemistry: Iupac Recommendations 2005. Royal Society of Chemistry.
2. Wentker M, Jüstel T, Leker J (2020) 4.15 Economic aspects. In: R Pöttgen, T Jüstel, CA Strassert (Eds.), De Gruyter STEM. Rare earth chemistry. Berlin, Boston: De Gruyter, pp. 611-628.
3. Jevons WS (1866) In Inquiry Concerning the Progress of the Nation, and the probable Exhausting of Our Coal-Mines (Vol. 2). Macmillan and Co.
4. Buhl J (2016) Rebound-Effekte im Steigerungsspiel. Zeit- und Einkommenseffekte in Deutschland. Nomos Verlagsgesellschaft.
5. Khazzoom DJ (1980) Economic Implications of Mandated Efficiency in Standards for Household Appliances. pp. 21-40.
6. Fouquet R, Pearson P (2006) Seven Centuries of Energy Services: The Price and Use of Light in the United Kingdom 27: 1300-2000.
7. Brookes LG (1978) Energy policy, the energy price fallacy and the role of nuclear energy in the UK. Energy Policy 6(2): 94-106.
8. Sorrell S (2007) The Rebound Effect: An assessment of the evidence for economy-wide energy savings from improved energy efficiency. Sussex Energy Group for the Technology and Policy Assessment function of the UK Energy Research Centre.
9. Madlener R, Alcott B (2011) Herausforderungen für eine technisch-ökonomische Entkopplung von Naturverbrauch und Wirtschaftswachstum. Unter besonderer Berücksichtigung der Systematisierung von Rebound-Effekten und Problemverschiebungen. Enquete-Kommission „Wachstum, Wohlstand, Lebensqualität“ des Deutschen Bundestages.
10. Alcott B (2005) Jevons' paradox. pp. 9-12.
11. Willenbacher M, Hornauer T, Wohlgenuth V (2022) Rebound Effects in Methods of Artificial Intelligence. In: V Wohlgenuth, S Naumann, G Behrens, HK Arndt (Eds.), Progress in IS. Advances and New Trends in Environmental Informatics. Cham: Springer International Publishing, USA, pp. 73-85.
12. Strubell E, Ganesh A, McCallum A (2019) Energy and Policy Considerations for Deep Learning in NLP.
13. Brown TL, LeMay HE, Bursten BE, Murphy CJ, Woodward PM, et al. (2018) Chemie. Studieren kompakt (Vol. 14). Pearson.
14. Röhr C (2021) Chemie der Metalle, Kap. 7.1.
15. IUPAC (2018) Periodic Table of Elements.
16. Stosch HG (2006) Geochemie der Seltenen Erden.
17. Sicius H (2015) Seltenerdmetalle und Metalle der dritten Nebengruppe - Physikalische und chemische Eigenschaften. Springer Spektrum.
18. Huheey JE, Keiter EA, Keiter RL, Stuedel R (2012) Anorganische Chemie. Prinzipien von Struktur und Reaktivität. De Gruyter.
19. Greenwood NN, Earnshaw A (1990) Chemie der Elemente. Wiley-VCH.
20. Holleck L, Eckardt D (1953) Komplexbildung und Term aufspaltung im Absorptionsspektrum Seltener Erden. Zeitschrift Für Naturforschung 8(10): 660-664.
21. Meschede D (2005) Optik, Licht und Laser (2., überarbeitete und erweiterte Auflage). Springer eBook Collection Life Science and Basic Disciplines. Wiesbaden: Vieweg+Teubner Verlag.
22. Nopper R (2003) Entwicklung von Verfahren zur Bestimmung von Spurengehalten Seltener Erden in verschiedenen Matrices mit ICP-AES nach Anreicherung und Abtrennung mittels Extraktionschromatographie.
23. Adler B, Müller R (2014) Seltene Erdmetalle. Gewinnung, Verwendung und Recycling. Berichte aus der Biomechanik. (Vol. 10). Fachgebiet Biomechanik an der TU Ilmenau.
24. Van Gosen BS, Verplanck PL, Seal RR, Long KR, Gambogi J, et al. (2017) Professional Paper.

International Journal of Environmental Sciences & Natural Resources

25. Institut für seltene Erden und Metalle AG (2021) Scandium.
26. Westphal WH (1952) *Physikalisches Wörterbuch*. Springer.
27. Haxel GB, Hedrick JB, Orris GJ (2002) *Rare Earth Elements—Critical Resources for High Technology*.
28. Edelmann FT (2021) *Seltene Erden: Kein iPod ohne Chinas exotische Rohstoffe*.
29. U.S. Department of the Interior & U.S. Geological Survey (2021) *Mineral Commodity Summaries 2021*. U.S. Geological Survey.
30. Marschall L, Holdinghausen H (2018) *Seltene Erden. Umkämpfte Rohstoffe des Hightech-Zeitalters*. Oekom Verlag.
31. Berger VI, Singer DA, Orris GJ (2009) *Carbonatites of the World, Explored Deposits of Nb and REE—Database and Grade and Tonnage Models*. U.S. Geological Survey.
32. Wältes A, Lusty P, Chetwyn C (2010) *Rare earth elements*. British Geological Survey.
33. Xie F, An Zhang T, Dreisinger D, Doyle F (2014) A critical review on solvent extraction of rare earths from aqueous solutions. *Minerals Engineering* 56: 10-28.
34. Adamas Intelligence (2021) *New Report from Adamas Intelligence: Rare Earth Magnet Market Outlook to 2030*.
35. Garcia AC, Latifi M, Amini A, Chaouki J (2020) Separation of Radioactive Elements from Rare Earth Element-Bearing Minerals. *Metals* 10(11): 1524.
36. Jiabao L, Jie L (2009) *Rare earth industry adjusts to slow market*. China Daily.
37. GEOMAR Helmholtz-Zentrum für Ozeanforschung Kiel (2019) *Mineralische Rohstoffe aus der Tiefsee. Entstehung, Potential und Risiken*.
38. *Mining Impact (2021) JPI Oceans*.
39. Tong SL, Zhu WZ, Gao ZH, Meng YX, Peng RL, et al. (2004) Distribution Characteristics of Rare Earth Elements in Children's Scalp Hair from a Rare Earths Mining Area in Southern China. *J Environ Sci Health A Tox Hazard Subst Environ Eng* 39(9): 2517-2532.
40. Wu L, Zhou YP, Zhong HJ (2003) A case-control study on the risk factors of leukemia in mining areas of rare-earth in South Jiangxi. *Zhonghua liu xing bing xue za zhi Zhonghua liuxingbingxue zazhi* 24(10): 879-882.
41. Gaman L, Delia CE, Luzardo OP, Zumbado M, Badea M, et al. (2019) Serum concentration of toxic metals and rare earth elements in children and adolescent. *Int J Environ Health Res* 30(6): 696-712.
42. Pagano G, Guida M, Tommasi F, Oral R (2015) Health effects and toxicity mechanisms of rare earth elements—Knowledge gaps and research prospects. *Ecotoxicology and Environmental Safety* 115: 40-48.
43. Tsamis A, Coyne M (2015) *Recovery of Rare Earths from Electronic Wastes: An Opportunity for High-Tech SMEs*.
44. Lucas J, Lucas P, Le Mercier T, Rolland A, Davenport WG (2014) *Rare Earths: Recycling: Science, Technology, Production and Use*.
45. Lorenz T, Bertau M (2019) *Das SepSELSA-Projekt - Wie man Seltene Erden aus Leuchtstoffröhren gewinnt*.
46. Lorenz T, Bertau M (2018) *Innovatives Recycling Seltener Erden durch Feststoffchlorierung*. *Chemie in Unserer Zeit* 52(5): 314-320.
47. Akcil A, Ibrahim YA, Meshram P, Panda S, Pillai A (2021) Hydrometallurgical recycling strategies for recovery of rare earth elements from consumer electronic scraps: a review. *Journal of Chemical Technology and Biotechnology* 96(7): 1785-1797.
48. European Commission (2018) *Report on Critical Raw Materials and the Circular Economy (Part 3/3)*.
49. Omodara L, Pitkäaho S, Turpeinen EM, Saavalainen P, Oravijärvi K, et al. (2019) *Recycling and substitution of light rare earth elements, cerium, lanthanum, neodymium, and praseodymium from end-of-life applications - A review*. *Journal of Cleaner Production* 236: 117573.
50. Schüler D, Buchert M, Liu R, Dittrich S, Merz C (2011) *Study on rare earths and their recycling*. Final report. U.S. Department of Energy, Office of Scientific and Technical Information.
51. *Interreg (2021) REEgain*.
52. Acevedo CF (2015) *Demonstration of the recovery of critical metals such as Indium and Yttrium by recycling discarded flat panels*.
53. Bogart JA, Lippincott CA, Carroll PJ, Schelter EJ (2015) *An Operationally Simple Method for Separating the Rare-Earth Elements Neodymium and Dysprosium*. *Angewandte Chemie* 54(28): 8222-8225.
54. Mattocks JA, Ho JV, Cotruvo JA (2019) *A Selective, Protein-Based Fluorescent Sensor with Picomolar Affinity for Rare Earth Elements*. *Journal of the American Chemical Society* 141(7): 2857-2861.
55. Cotruvo JA (2021) *Rare-Earth Element Biochemistry*. *Issn Ser. San Diego: Elsevier Science & Technology*.
56. Deblonde GJP, Mattocks JA, Park DM, Reed DW, Cotruvo JA, et al. (2020) *Selective and Efficient Biomacromolecular Extraction of Rare-Earth Elements using Lanmodulin*. *Inorganic Chemistry* 59(17): 11855-11867.
57. Dittrich C, Yagmurlu B (2018) *Scale: An Emerging Project for European Scandium Supply*. In *Symposium conducted at the meeting of ALTA 2018*.
58. Opwis K, Mayer-Gall T, Gutmann JS, Gronwald P, Schneider U, et al. (2018) *Rückgewinnung von Lanthan aus Rückständen der Raffineriekatalysatorherstellung für die Petrochemie mit Hilfe von Polyelektrolyt-ausgerüsteten Textilien*. *Band 11: 203-215*.
59. *Technische Universität Bergakademie Freiberg (2014) Das SepSELSA-Projekt*.
60. *Lederer F (2020) Helmholtz Zentrum Dresden Rossendorf*.
61. Smith GP (1985) *Filamentous fusion phage: Novel expression vectors that display cloned anti-gens on the virion surface*. *Science* 228(4705): 1315-1317.
62. Graedel TE, Harper EM, Nasser NT, Reck BK (2015) *On the materials basis of modern society*. *PNAS* 112(20): 6295-6300.
63. Panthak AK, Khan M, Gschneidner KA, McCallum RW, Zhou L, et al. (2015) *Cerium: An Unlikely Replacement of Dysprosium in High Performance Nd-Fe-B Permanent Magnets*. *Adv Mater* 27(16): 2663-2667.
64. Jesche A, Ke L, Jacobs JL, Harmon B, Houk RS, et al. (2015) *Alternating magnetic anisotropy of Li2(Li1-xTx)N(T=Mn,Fe,Co,andNi)*. *Physical Review B* 91(18).
65. *Wehrspohn R (2017) Leitprojekt "Kritikalität Seltener Erden"*.
66. *Cassagnol C, Krispin M, Zins I (2013) Siemens AG DE102013213646A1. Deutschland*.
67. Ito Y, Aoki T, Naito T, Hiranishi T (2019) *Development of Motor with Heavy Rare Earth-Free Magnet for Two-Motor Hybrid System*. *SAE International Journal of Advances and Current Practices in Mobility* 1(3): 1169-1176.
68. *Statista (2020) Anzahl der Smartphone-Nutzer weltweit von 2016 bis 2020 und Prognose bis 2024*.

**International Journal of Environmental Sciences & Natural Resources**

---

69. Bitkome V (2020) Die Zukunft der Consumer Technology: Studie 2020.
70. Arbeitsgemeinschaft Verbrauchs- und Medienanalyse (2021) Vuma Touchpoints 2020.
71. ARD/ZDF (2020) ARD/ZDF Massenkommunikation Trends 2020.
72. Statistisches Bundesamt (2020) Anteil der privaten Haushalte mit Personal Computern von 2000 bis 2020.
73. United Nations (2011) Human Development Report 2011. Technical Note 1. Calculating the Human Development Index.
74. United Nations (2020) World Population Prospects 2019.
75. Gröger J (2020) Digitaler CO2-Fußabdruck. Öko-Institut e.V.
76. Willenbacher M, Hornauer T, Wohlgemuth V (2021) A Short Overview of Rebound Effects in Methods of Artificial Intelligence. International Journal of Environmental Sciences & Natural Resources 28(5).
77. Mancheri NA, Sprecher B, Bailey G, Ge J, Tukker A (2019) Effect of Chinese policies on rare earth supply chain resilience. Resources, Conservation and Recycling 142: 101-112.



This work is licensed under Creative Commons Attribution 4.0 License  
DOI: 10.19080/IJESNR.2022.30.556277

**Your next submission with Juniper Publishers  
will reach you the below assets**

- Quality Editorial service
- Swift Peer Review
- Reprints availability
- E-prints Service
- Manuscript Podcast for convenient understanding
- Global attainment for your research
- Manuscript accessibility in different formats  
**( Pdf, E-pub, Full Text, Audio )**
- Unceasing customer service

**Track the below URL for one-step submission**  
<https://juniperpublishers.com/online-submission.php>

## 8. Publikationsliste

Im folgende sind alle Publikationen aufgelistet, die während der Promotionsphase entstanden.

Willenbacher, M., Wohlgemuth, V.: Neural Networks for Energy Optimization of Production Processes in Small and Medium Sized Enterprises. In: Wohlgemuth, V., Arndt, H.-K., Behrens, G., Naumann, S., Höb, M. (eds) *Advances and New Trends in Environmental Informatics*. Springer International Publishing, Cham (2023)

Willenbacher, M., Hornauer, T., Wohlgemuth, V.: Rebound Effects in Methods of Artificial Intelligence. In: Wohlgemuth, V., Naumann, S., Behrens, G., Arndt, H.-K. (eds) *Advances and New Trends in Environmental Informatics*. Progress in IS, pp. 73–85. Springer International Publishing, Cham (2022)

Willenbacher, M., Wohlgemuth, V.: Rebound Effects in the Use of Rare Earth Metals in ICT. *IJESNR* 30 (1) (2022). doi: 10.19080/IJESNR.2022.30.556277

Willenbacher, M.: A Short Overview of Rebound Effects in Methods of Artificial Intelligence. *IJESNR* 28 (5) (2021). doi: 10.19080/IJESNR.2021.28.556246

Willenbacher, M., Scholten, J., Wohlgemuth, V.: Machine Learning for Optimization of Energy and Plastic Consumption in the Production of Thermoplastic Parts in SME. *Sustainability* 13 (12), 6800 (2021). doi: 10.3390/su13126800

Lütje, A., Willenbacher, M., Engelmann, M., Kunisch, C., Wohlgemuth, V.: Exploring the System Dynamics of Industrial Symbiosis (IS) with Machine Learning (ML) Techniques—A Framework for a Hybrid-Approach. In: Schaldach, R. (ed) *Advances and New Trends in Environmental Informatics: ICT for Sustainable Solutions*. Progress in IS Ser, pp. 117–130. Springer International Publishing AG, Cham (2020)

Lütje, A., Willenbacher, M., Möller, A., Wohlgemuth, V.: Enabling the Identification of Industrial Symbiosis (IS) through Information Communication Technology

(ICT) Proceedings of the Hawaii International Conference on System Sciences (HICSS) (2019)

Willenbacher, M., Kunisch, C., Wohlgemuth, V.: Application of Methods of Artificial Intelligence for Sustainable Production of Manufacturing Companies. In: Otjacques, B., Hitzelberger, P., Naumann, S., Wohlgemuth, V. (eds) From Science to Society. Progress in IS, pp. 225–236. Springer International Publishing, Cham (2018)

Willenbacher, M., Wohlgemuth, V.: Einsatzmöglichkeiten von Methoden der Künstlichen Intelligenz zur Optimierung von Stoff- und Energieströmen und prototypische Umsetzung auf der Basis von Stoffstromnetzen. In: Arndt, H.-K., Marx Gómez, J., Wohlgemuth, V., Lehmann, S., Pleshkanovska, R. (eds) Nachhaltige Betriebliche Umweltinformationssysteme, pp. 97–108. Springer Fachmedien Wiesbaden, Wiesbaden (2018)

Willenbacher, M.; Wohlgemuth, V.: Machine Learning for Sustainable Logistics. In: Environmental Informatics. Hg. von Hans-Joachim Bungartz, Dieter Kranzlmüller, Volker Weinberg, Jens Weismüller, Volker Wohlgemuth. Aachen: Shaker Verlag 2018, S. 250-253. (2018)

Willenbacher, M., Lepiorz, R. & Wohlgemuth, V., (2017). Serious Games, Umweltbewusstsein und Nachhaltigkeit. In: Eibl, M. & Gaedke, M. (Hrsg.), INFORMATIK 2017. Gesellschaft für Informatik, Bonn. (S. 2017-2026). DOI: 10.18420/in2017\_202

## Literaturverzeichnis

Association for Computing Machinery (Hg.) (1975) *Computer Science as Empirical Inquiry: Symbols and Search: ACM Turing Award Lecture* [Online], Pittsburgh, Carnegie-Mellon University (Volume 19 Number 3). Verfügbar unter [https://dl.acm.org/ft\\_gateway.cfm?id=1283930&type=pdf](https://dl.acm.org/ft_gateway.cfm?id=1283930&type=pdf) (Abgerufen am 14 Januar 2023).

Baek, E., Das, N. R., Cannistraci, C. V., Rim, T., Bermúdez, G. S. C., Nych, K., Cho, H., Kim, K., Baek, C.-K., Makarov, D., Tetzlaff, R., Chua, L., Baraban, L. & Cuniberti, G. (2020) „Intrinsic plasticity of silicon nanowire neurotransistors for dynamic memory and learning functions“, *Nature Electronics*, Vol. 3, No. 6, S. 346.

Berlit, P. (2020) *Klinische Neurologie*, 4. Aufl., Berlin, Heidelberg, Springer Berlin Heidelberg.

Braun, S. & Kay, R. (2021) *Unternehmensgrößenstatistik 2019: Auswirkungen der Berücksichtigung geringfügig Beschäftigter im Unternehmensregister auf die KMU-Kennzahlen*, Bonn, Institut für Mittelstandsforschung (IfM).

Bundesministerium für Wirtschaft und Klimaschutz (Hg.) (2022) *Energiedaten: Gesamtausgabe* [Online]. Verfügbar unter [https://www.bmwk.de/Redaktion/DE/Binaer/Energiedaten/energiedaten-gesamt-xls-2022.xlsx?\\_\\_blob=publication-file&v=8](https://www.bmwk.de/Redaktion/DE/Binaer/Energiedaten/energiedaten-gesamt-xls-2022.xlsx?__blob=publication-file&v=8) (Abgerufen am 13 Januar 2023).

Churchland, P. S. & Sejnowski, T. J. (2016) *The computational brain*, 25. Aufl., Cambridge, Massachusetts, The MIT Press.

Eagleman, D. M. (2021) *How our brains could create whole new senses* [Online], London. Verfügbar unter <https://www.newscientist.com/article/mg25033340-900-david-eagleman-interview-how-our-brains-could-create-whole-new-senses/> (Abgerufen am 26 Februar 2023).

Europäische Kommission (2003) *Empfehlung der Kommission vom 6. Mai 2003 betreffend die Definition der Kleinstunternehmen sowie der kleinen und mittleren Unternehmen.*

European Commission, Directorate-General for Internal Market, Industry, Entrepreneurship, SMEs, Muller, P., Ladher, R., Booth, J., Mohamed, S., Gorgels, S., Priem, M., Blagoeva, T., Martinelle, A., Milanesi, G. & Hope, K. (2022) *Annual report on European SMEs 2021/2022 : SMEs and environmental sustainability*, Publications Office of the European Union.

Friedrich, R. (2021) *Potenziale der schwachen künstlichen Intelligenz für die betriebliche Ressourceneffizienz*, Berlin, VDI Zentrum Ressourceneffizienz GmbH (VDI ZRE).

Gröger, J. (2020) *Digitaler CO<sub>2</sub>-Fußabdruck: Datensammlung zur Abschätzung von Herstellungsaufwand, Energieverbrauch und Nutzung digitaler Endgeräte und Dienste* [Online], Berlin, Öko-Institut e.V. Verfügbar unter <https://www.oeko.de/fileadmin/oekodoc/Digitaler-CO2-Fussabdruck.pdf> (Abgerufen am 23 November 2022).

Herculano-Houzel, S. (2009) „The human brain in numbers: a linearly scaled-up primate brain“, *Frontiers in human neuroscience*, Vol. 3, S. 31.

Hevner, March, Park & Ram (2004) „Design Science in Information Systems Research“, *MIS Quarterly*, Vol. 28, No. 1, S. 75 [Online]. DOI: 10.2307/25148625.

Hevner, A. R. (2007) „A Three Cycle View of Design Science Research“, *Scandinavian Journal of Information Systems*, Vol. 19, S. 4.

Icha, P. & Kuhs, G. (2019) *Entwicklung der spezifischen Kohlendioxid-Emissionen des deutschen Strommix in den Jahren 1990 - 2018* [Online] (Climate Change 10/2019).

- Institut für Mittelstandsforschung Bonn (2022) *Mittelstand im Einzelnen* [Online], Bonn, Institut für Mittelstandsforschung. Verfügbar unter <https://www.ifm-bonn.org/statistiken/mittelstand-im-einzelnen> (Abgerufen am 12 Januar 2023).
- Jevons, W. S. (1865) *The Coal Question: An Enquiry Concerning the Progress of the Nation, and the Probable Exhaustion of Our Coal-mines* [Online], Macmillan. Verfügbar unter <https://books.google.de/books?id=gAAKAAAAIAAJ>.
- Kaul, A., Schieler, M. & Hans, C. (2019) *Künstliche Intelligenz im europäischen Mittelstand: Status quo, Perspektiven und was jetzt zu tun ist*, Saarbrücken, Universität des Saarlandes.
- Kurreck, J, Engels, JW & Lottspeich, F (Hg.) (2022) *Bioanalytik*, 4. Aufl., Berlin, Springer Spektrum.
- Mittelstand 4.0-Kompetenzzentrum - IT Wirtschaft *IT2Match (2.1-LIVE)* [Computerprogramm]. Verfügbar unter <https://www.it2match.de/> (Abgerufen am 14 März 2023).
- Müller, E., Schmitt, S., Mauch, C., Billaudelle, S., Grübl, A., Güttler, M., Husmann, D., Ilmberger, J., Jeltsch, S., Kaiser, J., Klähn, J., Kleider, M., Koke, C., Montes, J., Müller, P., Partzsch, J., Passenberg, F., Schmidt, H., Vogginger, B., Weidner, J., Mayr, C. & Schemmel, J. (2022) „The operating system of the neuromorphic BrainScaleS-1 system“, *Neurocomputing*, Vol. 501, S. 790–810.
- Myers, D. G. (2014) *Psychologie* [Online], 3. Aufl., Berlin, Heidelberg, Springer Berlin Heidelberg. Verfügbar unter <http://nbn-resolving.org/urn:nbn:de:bsz:31-epflicht-1495477>.
- Peppers, K., Tuunanen, T., Rothenberger, M. A. & Chatterjee, S. (2007) „A Design Science Research Methodology for Information Systems Research“, *Journal of Management Information Systems*, Vol. 24, No. 3, S. 45–77.
-

Rammer, C., Gottschalk, S., Peters, B., Bersch, J. & Erdsiek, D. (2016) *Die Rolle von KMU für Forschung und Innovation in Deutschland: Studie im Auftrag der Expertenkommission Forschung und Innovation*, Berlin, Expertenkommission Forschung und Innovation (EFI).

Russell, S. J. & Norvig, P. (2021) *Artificial intelligence: A modern approach*, Hoboken, Pearson.

Silver, M. S., Markus, M. L. & Beath, C. M. (1995) „The Information Technology Interaction Model: A Foundation for the MBA Core Course“, *MIS Quarterly*, Vol. 19, No. 3, S. 361.

Simon, H. A. (1996) *The sciences of the artificial*, 3. Aufl., Cambridge, Mass., MIT Press.

Statistisches Bundesamt (2023) *Statistik für kleine und mittlere Unternehmen: Code: 48121* [Online]. Verfügbar unter <https://www-genesis.destatis.de/genesis/online> (Abgerufen am 12 Januar 2023).

Talens Peiró, L. & Villalba Méndez, G. (2013) „Material and Energy Requirement for Rare Earth Production“, *JOM*, Vol. 65, No. 10, S. 1327–1340.

U.S. Department of the Interior & U.S. Geological Survey (2021) *Mineral Commodity Summaries 2021* [Online]. Verfügbar unter <https://www.usgs.gov/centers/nmic/mineral-commodity-summaries>.

UK Parliamentary Office of Science and Technology (Hg.) (2022) *Energy consumption of ICT* [Online], London (Number 677). Verfügbar unter <https://research-briefings.files.parliament.uk/documents/POST-PN-0677/POST-PN-0677.pdf> (Abgerufen am 13 Januar 2023).

United Nations (2011) *Human Development Report 2011. Technical Note 1. Calculating the Human Development Index* [Online].

United Nations (2020) *World Population Prospects 2019* [Online], New York.

---

Whitehead, A. N. & Russell, B. (1925-1927) *Principia Mathematica*, Cambridge University Press.

Wilde, T. & Hess, T. (2006) *Methodenspektrum der Wirtschaftsinformatik: Überblick und Portfoliobildung 2/2006* [Online]. Verfügbar unter <http://hdl.handle.net/10419/60077>.

## Anhang A: Beitrag des Autors zu den Veröffentlichungen

Hiermit reiche ich für jeden eingereichten Artikel eine Autorenerklärung ein, in der ich meinen individuellen wissenschaftlichen Beitrag zur Erstellung des Artikels und den Anteil meines eigenen Beitrags im Verhältnis zum Beitrag der anderen Co-Autoren insgesamt darlege.

Hiermit bestätige ich, dass die Angaben in der folgenden Tabelle wahrheitsgemäß und korrekt sind.

Alle Artikel wurden begutachtet (peer review) und sind bereits veröffentlicht.

Tabelle 10: Überblick über den Beitrag des Autors zu den Veröffentlichungen

Veröffentlichte und begutachtete Artikel	Beitrag	Anteil %	Präsentation
Willenbacher, M.; Scholten, J.; Wohlgemuth, V. Machine Learning for Optimization of Energy and Plastic Consumption in the Production of Thermoplastic Parts in SME. Sustainability 2021, 13 (12): 6800 (2021). doi: 10.3390/su13126800	Konzeptionalisierung des Forschungsansatzes	90 %	<ul style="list-style-type: none"> <li>Vorstellung des Projektes auf dem HTW-Infoveranstaltungsstand der HANNOVER MESSE 2019, Hannover, 04.04.2019</li> <li>Vortrag auf der Veranstaltung „Berlin machts's effizient“ des Bundesministeriums für Wirtschaft und Energie (BMWi), Berlin Partner für Wirtschaft und Technologie GmbH, VDI Zentrum Ressourceneffizienz, Berlin, 09.05. 2019</li> </ul>
	Methodik	100 %	
	Software und Datenpflege, Validierung	65 %	
	Analyse und Interpretation	70 %	
	Schreiben des Originalentwurfs	85 %	
	Rezension und Überarbeitung, Visualisierung	85 %	
	Projektverwaltung	100 %	

Veröffentlichte und begutachtete Artikel	Beitrag	Anteil %	Präsentation
	Gewichtungsfaktor*	1,0	<ul style="list-style-type: none"> <li>• Workshop „Machine Learning in the Environmental Sciences“ auf der EnviroInfo 2019, Kassel, 26.09.2019</li> <li>• Vortrag auf dem 7. Geyer Wissenstag, Berlin, 16.06.2023</li> </ul>
Willenbacher, M.; Wohlgemuth, V.; Risch, L. Neural Networks for Energy Optimization of Production Processes in Small and Medium Sized Enterprises. In: Wohlgemuth, V.; Naumann, S.; Behrens, G.; Arndt, H.-K.; Höb, M. (eds). Advances and New Trends in Environmental Informatics. pp. 129–145. Springer International Publishing. Cham (2023). doi: 10.1007/978-3-031-18311-9_8	Konzeptionalisierung des Forschungsansatzes	90 %	<ul style="list-style-type: none"> <li>• Vortrag auf der Enviro-Info 22, Hamburg, 27.09.2022</li> <li>• Vortrag auf der 18<sup>th</sup> Global Conference on Sustainable Manufacturing (GCSM), Potsdam, 07.10.2022</li> <li>• Vortrag auf dem 2<sup>nd</sup> Symposium on Sustainable Production and Digitalization, Kairo (Ägypten), 20.10.2022</li> </ul>
	Methodik	85 %	
	Software und Datenpflege, Validierung	65 %	
	Analyse und Interpretation	70 %	
	Schreiben des Originalentwurfs	90 %	
	Rezension und Überarbeitung, Visualisierung	85 %	
	Projektverwaltung	100 %	
	Gewichtungsfaktor	1,0	
	Konzeptionalisierung des Forschungsansatzes	100 %	

\* Gemäß §14 der Richtlinie zur kumulativen Dissertation beschlossen am 15. Januar 2012 (Dr. phil.) / 23. Januar 2012 (Dr. rer. pol.) / 24. Januar 2012 (Dr. rer. nat.) der Leuphana Universität Lüneburg

Veröffentlichte und begutachtete Artikel	Beitrag	Anteil %	Präsentation
Willenbacher, M.; Wohlgemuth, V. Rebound Effects in the Use of Rare Earth Metals in ICT, IJESNR 30 (1) (2022), doi: 10.19080/IJESNR.2022.30.556277	Methodik	100 %	<ul style="list-style-type: none"> <li>Vortrag auf der Enviro-Info 2021, Berlin, 27.09.2021</li> </ul>
	Software und Datenpflege, Validierung	100 %	
	Analyse und Interpretation	100 %	
	Schreiben des Originalentwurfs	100 %	
	Rezension und Überarbeitung, Visualisierung	85 %	
	Projektverwaltung	100 %	
	Gewichtungsfaktor	1,0	

---

## **Anhang B:       Betreute studentische Arbeiten**

Ergebnisse und Erkenntnisse der Forschungsarbeiten in der Promotionsphase gingen in studentische Arbeiten ein. Diese von mir betreuten Arbeiten sind im Folgenden aufgelistet:

Bönisch, Maximilian (2019) *Konzept zur Einführung von maschinellem Lernen (Herculano-Houzel, 2009) im Kontext der betrieblichen Nachhaltigkeit in mittelständischen Unternehmen*. Masterarbeit, HTW Berlin, Fachbereich 2 – Ingenieurwissenschaften, Studiengang Betriebliche Umweltinformatik

Risch, Lisa (2020) *Machine Learning for Increasing Resource Efficiency in a Production SME in the Automotive Industry*. Bachelorarbeit, HTW Berlin, Fachbereich 2 – Ingenieurwissenschaften, Studiengang Umweltinformatik

Scholten, Jonas (2020) *Machine Learning als Werkzeug zur Optimierung des CO<sub>2</sub>- und Plastikverbrauchs bei der Produktion von thermoplastischen Kunststoffen eines Automobilzulieferers mittels Big Data Analyse*. Masterarbeit, HTW Berlin, Fachbereich 1 – Energie und Information, Studiengang Computer Engineering