


Einsatz von Künstlicher Intelligenz in der Digitalisierung von Abfallverbrennungskraftwerken

Ein Praxisbericht

Alexandra Pehlken ¹, Patrick Eschemann², Henriette Garmatter³, Fabian Cyris⁴,
Astrid Nieße⁵

Abstract: Die thermische Verwertung von Abfällen in Abfallverbrennungskraftwerke gestaltet sich als komplexe Aufgabe, da das vorrangige Ziel die Abfallbehandlung vor dem Ziel der Energiegewinnung steht. Insbesondere die Heterogenität des aus verschiedenen Abfällen bestehenden Brennstoffes stellt vielseitige Anforderungen an den Betrieb. Zur Optimierung der Betriebsführung von Dampferzeugern in Abfallverbrennungskraftwerken auf Basis der Maximierung des Durchsatzes, der Optimierung der Strom- und Wärmeproduktion sowie der Maximierung der Standzeit der Kraftwerkskomponenten unter Berücksichtigung der Emissionsgrenzwerte werden die im Kraftwerk erhobenen Messdaten eingesetzt sowie Bilddaten erhoben.


Diese werden aufbereitet und vortrainierten neuronalen Netzen zugeführt, mit dem Ziel verschiedene Materialien zu klassifizieren, um Informationen über die Abfallzusammensetzung und dem Heizwert zu erhalten.

Keywords: KI, Bilderkennung, Kraftwerk, Abfall, Verbrennung

1 Einleitung

Die nachhaltige Nutzung von Rohstoffen ist eine der zentralen Herausforderungen unserer Gesellschaft. Insbesondere in der Energieversorgung und in der Produktion von Verbrauchsgütern ist eine Effizienzsteigerung bei der Verwendung von Rohstoffen notwendig, um für zukünftige Generationen eine Versorgung mit endlichen Rohstoffen sicherzustellen.

In der EU-Abfallrahmenrichtlinie [Ri08] wurden 2008 die Rahmenbedingungen für die zukünftige Abfallwirtschaft festgelegt und 2012 im Kreislaufwirtschaftsgesetz [Ge12] in

¹ OFFIS – Institut für Informatik, Escherweg 2, 26121 Oldenburg, pehlken@offis.de, 
<https://orcid.org/0000-0003-1798-8679>

² OFFIS – Institut für Informatik, Escherweg 2, 26121 Oldenburg, patrick.eschemann@offis.de

³ Institut für Kraftwerkstechnik und Wärmeübertragung, Leibniz Universität Hannover, An der Universität 1,
30823 Garbsen, garmatter@ikw.uni-hannover.de

⁴ EEW Energy from Waste GmbH, Schöniger Straße 2-3, 38350 Helmstedt, Fabian.Cyris@eew-
energyfromwaste.com

⁵ OFFIS – Institut für Informatik, Escherweg 2, 26121 Oldenburg, astrid.niesse@offis.de

Deutschland umgesetzt. Ziel der Richtlinie und des Gesetzes ist, die Kreislaufwirtschaft zu fördern und die Rohstoffverwertung umweltschonend zu gestalten. Aufgrund des seit 2005 geltenden Deponierungsverbotes in Deutschland für unbehandelte Siedlungsabfälle wird der größte Anteil aller anfallenden Siedlungsabfälle thermisch in einer Abfallverbrennungsanlage behandelt [Ve01]. Als übergeordnetes Ziel werden bei der thermischen Verwertung in den Abfällen enthaltene Schadstoffe reduziert und neutralisiert sowie das Volumen der Abfälle verringert. Allerdings lässt sich in einem Abfallverbrennungskraftwerk auch der positive Nebeneffekt nutzen, die in den Abfällen gebundene chemische Energie zurück zu gewinnen und als Elektrizität und Wärme der Bevölkerung und der Industrie zur Verfügung zu stellen. Neben der Volumenreduktion, die von erheblichem ökonomischem Interesse ist, stellt somit die energetische Verwertung einen weiteren gewichtigen Grund für die thermische Verwertung – auch unter der Maßgabe einer umfassenden Energieeffizienzbetrachtung – dar. Abfallverbrennungsanlagen tragen somit einen großen Beitrag zur den 17 Nachhaltigkeitszielen der Vereinten Nationen bei, da sie zum Beispiel durch Abfallbehandlung erreicht lebenswerte Städte zu schaffen. Außerdem schafft die Kreislaufwirtschaft, dessen Teil die Abfallverbrennungsanlagen sind, Einkommen und schützt die Gesundheit. Allerdings kann hier die Effizienz noch gesteigert werden.

Die Umsetzung einer effizienten thermischen Verwertung in einem Abfallverbrennungskraftwerk gestaltet sich als komplexe Aufgabe. Insbesondere die Heterogenität des aus verschiedenen Abfällen bestehenden Brennstoffes stellt vielseitige Anforderungen an den Betrieb. Die Universität Hannover und das OFFIS – Institut für Informatik Oldenburg erarbeiten gemeinsam eine Methode, um unter Einhaltung der Emissionsgrenzwerte den Durchsatz zu steigern und somit ineffiziente Anlagen zu verdrängen. Zusätzlich wird durch eine geeignete Betriebsführung die Maximierung von Wirkungsgrad und Standzeit der Bauteile angestrebt um sowohl die Nachhaltigkeit als auch die Wirtschaftlichkeit der thermischen Abfallverwertung zu steigern. Die Maximierung des Wirkungsgrades ermöglicht die optimale Nutzung der im Abfall chemisch gebundenen Energie. Die Bauteilstandzeit wird maßgeblich von Korrosion durch Bestandteile der Abfälle bestimmt. Eine Verlängerung der Bauteilstandzeit durch eine geeignete Betriebsführung reduziert ressourcenintensive Instandhaltungsmaßnahmen und steigert die Anlagenverfügbarkeit.

Zur Optimierung der Betriebsführung werden derzeit kaum Methoden aus dem Bereich der künstlichen Intelligenz angewandt. Der vorliegende Beitrag zeigt erste Ergebnisse des Forschungsprojektes Abfallverbrennungskessel 4.0⁶, welches in Zusammenarbeit mit einer realen Abfallverbrennungsanlage, der EEW Energy from Waste (EEW), durchgeführt wird. Die im laufenden Betrieb erhobenen Sensordaten werden mit Hilfe von Data-Mining und Machine-Learning Verfahren in Kombination von Bilderkennung

⁶ Gefördert durch das Bundesministerium für Wirtschaft und Energie aufgrund eines Beschlusses des Deutschen Bundestages, FKZ 03EE5038

ausgewertet und zur Vorhersage des Heizwertes und der Brenneigenschaften des Abfalls eingesetzt.

2 Stand der Technik in Abfallverbrennungskraftwerken

In Abfallverbrennungskraftwerken werden Abfälle thermisch verwertet. Das primäre Ziel der thermischen Verwertung ist die Reduzierung und Neutralisierung der enthaltenen Schadstoffe sowie die Volumenreduzierung. Zusätzlich wird in den Abfallverbrennungskraftwerken die chemisch gebundene Energie zurückgewonnen und in Elektrizität und Wärme umgewandelt [Kr17].

Die im Abfallverbrennungskraftwerk als Brennstoff eingesetzten Abfälle verfügen über sehr heterogene Brenneigenschaften [Ch11]. Die Abfalleigenschaften sind zum Zeitpunkt der Aufgabe des Abfalls in die Verbrennung unbekannt und unterliegen unvorhersehbaren Schwankungen. Die Betriebsführung eines Abfallverbrennungskraftwerks muss daher laufend auf die momentanen vorliegenden Abfalleigenschaften angepasst werden. Aufgrund des heterogenen Brennstoffes werden in Abfallverbrennungsanlagen robuste Feuerungssysteme und spezielle Abgasreinigungstechniken eingesetzt. Abbildung 1 zeigt den Aufbau einer typischen Abfallverbrennungsanlage mit Rostfeuerung in Horizontal-Bauweise. Der angelieferte Abfall wird in einem Abfallbunker zwischengelagert, wo er mit Greifern zur Homogenisierung durchmischt wird. Mit Hilfe der Greifer gelangt der Abfall über einen Aufgabetrichter auf einen Rost, wo er unter Zufuhr von Luft verbrennt. Die dabei entstehenden Rauchgase durchströmen einen Dampferzeuger und gelangen von dort in die Abgasreinigung, wo sie so gereinigt werden, dass sie die Anlage unter Einhaltung der gesetzlich festgelegten Emissionsgrenzwerte die Anlage verlassen. Die Abgaswerte werden online von der Aufsichtsbehörde überwacht. Im Dampferzeuger geben die Rauchgase Wärme an ein Wasserdampf-Gemisch ab, das in einem Wasserdampfkreislauf zur Erzeugung von Strom genutzt wird. Gleichzeitig wird im Wasserdampfkreislauf auch Energie zur Bereitstellung von Fernwärme oder Prozessdampf für Industriekunden ausgekoppelt.

Aufgrund des heterogenen Brennstoffes müssen Dampferzeuger von Abfallverbrennungskraftwerken spezielle Anforderungen erfüllen. Zum einen resultieren diese Anforderungen aus den im Rauchgas enthaltenen Schadstoffen. Einige Schadstoffe können im Dampferzeuger durch hohe Temperaturen bei gleichzeitig langsamen Rauchgastemperaturen effizient zerstört werden. Dieser Prozess ist ein zentraler Bestandteil der Abgasreinigung in einem Abfallverbrennungskraftwerk und muss somit im Dampferzeugerbetrieb jederzeit gewährleistet sein. Zum anderen führt die heterogene Zusammensetzung des Abfalls zu Schwankungen von Temperaturen, Drücken, Rauchgasmengen und der produzierten Dampfmengen. Um auf diese Schwankungen möglichst gut zu reagieren werden zahlreiche Messdaten erhoben. Diese werden teilweise für eine automatisierte Feuerleistungsregelung verwendet. Viele Messdaten können jedoch aufgrund ihrer komplexen Abhängigkeiten in der Feuerleistungsregelung nicht

berücksichtigt werden. Diese Messdaten werden verwendet, um kurzfristig manuelle Eingriffe in die Feuerleistungsregelung vorzunehmen und langfristige Analysen zur Zustandsbewertung des Dampferzeugers vorzunehmen.




Abb. 1: Aufbau eines Abfallverbrennungskraftwerks mit Rostfeuerung in Horizontal-Bauweise [Cy21]

3 Anwendung von KI im Kontext der Bilderkennung von Abfallstoffen)

Aufgrund der hohen Heterogenität des Abfalls schwankt der zu erwartende Heizwert zwischen 8–20 MJ/kg⁷. Generell kann eine Abfallverbrennungsanlage den Verbrennungsprozess mit einem niedrigen Heizwert dauerhaft aufrechterhalten. Problematischer als zu hohe oder zu niedrige Heizwerte sind unerwartete, größere Schwankungen, die Gegenmaßnahmen nach sich ziehen. Hierbei werden durch Eingriffe in die Feuerleistungsregelung z.B. durch Änderungen der zugeführten Verbrennungsluft

⁷ Gemäß Auswertung vorliegender Sensordaten

oder durch Einbringung von Zusatzbrennstoffen (Heizöl oder Gas) die Effekte des schwankenden Heizwerts ausgeglichen.

Die Bilderkennung kann hier genutzt werden, um automatisiert und frühzeitig eine Abschätzung zum voraussichtlichen Heizwert des Abfalls zu gewinnen und die Verbrennung des Abfalls möglichst vorausschauend und effizient zu gestalten. Durch den Zeitverzug zwischen Abfallaufnahme und der eigentlichen Verbrennung vergehen durchschnittlich 87 Minuten, in denen der aufgegebene Abfall hinsichtlich des zu erwartenden Heizwerts analysiert und der Kraftwerksbetrieb entsprechend vorausschauend angepasst werden kann.

Im nachfolgenden wird der Einsatz von Transfer-Learning und das Konzept zum Training eines eigenen, auf die Problemstellung zugeschnittenen neuronalen Netzes vorgestellt.

3.1 Transfer-Learning

Für den Ansatz des Transfer-Learnings wurde das im Jahr 2014 von Simonyan und Zisserman [SiZi14] vorgestellte vgg16-Netz verwendet. Dieses wurde mit 14 Millionen Bildern vortrainiert, um 1000 unterschiedliche Objektklassen zu erkennen [Im21]. Ein Abgleich der Liste erkennbarer Objekte mit typischerweise in Abfall vorkommenden Gegenständen zeigt u. a. folgende Übereinstimmungen auf:

- Bierflasche, Bierglas, Flasche, Autoreifen, Tetrapak, Plastiktüte und andere

Relevant ist u. a. die Erkennung von Plastikbeuteln. Bei ersten Untersuchungen zeigte sich, dass das vortrainierte Netz diese zuverlässig erkennen kann. Die Akkuratheit hängt von der benutzereingestellten Genauigkeitsschranke und der Filtergröße, mit der das Bild durchsucht wird ab. Bei einer hohen Genauigkeitsschranke, treten kaum Fehlerkennungen auf (hohe Präzision). In Vorversuchen mit einer Genauigkeitsschranke >80 zeigt sich folgende Konfusion-Matrix:

True Positives (TP): 10	False Positives (FP): 0
False Negatives (FN): 3	True Negatives (TN): 0

$$\text{Präzision} = \frac{TP}{TP+FP} = 1$$

$$\text{Trefferquote} = \frac{TP}{TP+FN} \approx \sim 0.76$$

$$\text{F1-Score} = 2 * \frac{\text{Präzision} * \text{Trefferquote}}{\text{Präzision} + \text{Trefferquote}} \approx 0.86$$

Auf Abbildung 2 können je nach eingestellter Genauigkeit mit einer Sicherheit von >80 % Müllbeutel erkannt werden, wohingegen das vgg16-Netz auf Abbildung 3 keine sinnvollen Erkennungen ausgibt. Mit teilweisen hohen Wahrscheinlichkeiten erkannte das Netz Seekühe, Krawattenknoten oder Mäntel (F1-Score < 0.1).

Die durchgeführten Experimente weisen somit einerseits auf die Notwendigkeit besserer Videoaufnahmen im Kraftwerk, andererseits auf die Notwendigkeit eines speziell auf die Problemstellung trainierten neuronalen Netzes hin.

3.2 Konzept zum Training eines neuronalen Netzes

Grundsätzlich wird das neuronale Netz zur Regressionsanalyse verwendet, da dieses auf der letzten Ebene mit einem Neuron einen diskreten, kontinuierlichen Wert vorhersagen soll. Um ein neuronales Netz auf diese Aufgabenstellung zu trainieren, wird ein Trainingsdatensatz benötigt. Dieser muss Abfallbilder und die Zielgröße (Regressand) enthalten.

Als Regressanden eignen sich folgende zentrale Untersuchungsgrößen zum Verbrennungsvorgang:

- Emissionswerte (Quecksilber Hg, Schwefeldioxid SO₂, Kohlenstoffmonoxid CO, Kohlenstoffdioxid CO₂, Stickoxide NO_x, Ammoniak NH₃)
- Frischdampfmassenstrom in kg/s
- Heizwert in MJ/kg

Die Emissionswerte und der Frischdampfmassenstrom werden dauerhaft durch Sensoren im Dampferzeuger gemessen. Der Heizwert kann nicht direkt durch Sensoren erhoben werden, sondern wird unter Verwendung erhobener Messdaten bilanziert [Be12]. Obgleich der Heizwert für die vorausschauende Betriebsführung die interessanteste Größe darstellt, ist er aufgrund der Bilanzierung die Untersuchungsgröße mit der größten Unsicherheit. Diese Unsicherheit entsteht, da zahlreiche Messdaten in die Bilanzierung einfließen, welche jeweils mit einer Messungenauigkeit behaftet sind. Zusätzlich treten im Kraftwerksbetrieb immer wieder Defekte bei Sensoren auf. Entsprechend können fehlerhafte Messwerte in die Heizwertberechnung einfließen und diese beeinflussen.

Nach Stand der Technik werden Convolutional Neural Networks (CNN – zu deutsch Faltende neuronales Netz) zur Bilderkennung verwendet. Diese weisen vergleichbare Konnektivitätsmuster von Neuronenbahnen des menschlichen Gehirns auf und sind daher geeignet, um Aspekte bzw. Objekte in einem Bild zu identifizieren [Hou21]. Durch verschiedene Filter, die über ein Bild gelegt werden, werden vorwiegend Strukturen bspw. Kanten erkannt. Fraglich ist, ob das Auftreten von mehr kantigen oder runden Konturen, einen Zusammenhang zum Heizwert bzw. den übrigen Untersuchungsgrößen hat.

3.2.1 Automatisierte Erstellung der Bilddaten

Die Bilddaten stellen den Input für das neuronale Netz dar. Eine Abfallmenge zwischen 3-7 t wird regelmäßig durch einen Greifer in einen Trichter aufgegeben. Von dort wird der Abfall in den Verbrennungsraum gefördert. Die Abfallaufgabe wird durch eine Videokamera ganztägig aufgezeichnet.

Zur Verarbeitung des Videostreams wurde ein Pythonskript geschrieben, welches automatisiert die Abwurfsequenzen in Video- und Einzelbildformat extrahiert. Mithilfe der für Bildverarbeitung frei nutzbaren Programmbibliothek OpenCV [Bra00] wird die Extraktion relevanten Bildsequenzen aus dem Videostream der Überwachungskamera nach folgendem Schema automatisiert:

1. Bewegungserkennung durch Differenzbildung zweier aufeinanderfolgender Frames.
2. Umwandlung des differenzierten Bildes in Graustufen und Weichzeichnung mit Gaußschem Weichzeichner.
3. Einstellung eines Schwellenwertes für die bereinigte Bilddifferenz. Jeder Bildpunkt wird mit dem eingestellten Schwellenwert verglichen. Ist der Pixelwert kleiner als der Schwellenwert, wird er der Farbe Schwarz zugeordnet, ist er größer, wird er der Farbe Weiß zugeordnet.
4. Dilatation bzw. Glättung von Linien/Kanten, die die Schwellenwerterkennung negativ beeinflussen können.
5. Ermittlung und Zählung aller erkannten Konturen im Bild.
6. Überschreitet die Anzahl der sich bewegenden Konturen einen experimentell bestimmten Schwellenwert, wird die Extraktion ausgelöst.
7. Bei Beginn der Extraktion, wird per Optical Character Recognition (OCR) [Ho21] die Zeitsignatur aus dem ersten Frame des Abwurfs ausgelesen. Für den Abwurf wird ein entsprechend benannter Ordner erstellt, in dem die Extraktionsdaten abgelegt werden.
8. Sinkt die Anzahl der sich bewegenden Konturen unter die untere Schwelle, wird die Extraktion beendet.

Fehlerkennungen werden durch eine Datennachbehandlung ebenfalls automatisiert entfernt. Erkannt werden Fehlerkennungen gemäß folgender zwei Bedingungen:

- Zwei Abwürfe sind zeitlich zu nah nacheinander
- Anzahl der einzelnen Frames eines erkannten Abwurfes weicht im Vergleich zu den übrigen Abwürfen deutlich ab

Bei Tests an einem 8 Stunden Videostream wurden 32 verwertbare Abwürfe extrahiert. Dies stimmt mit den Daten aus der Leitzentrale des Kraftwerks zu tatsächlich erfolgten

Abwürfen überein. Die Verarbeitung des Videostreams läuft auf der hiesigen Hardware mit 3-5-facher Geschwindigkeit.

Bezogen auf den Labeln-Prozess von Trainingsdaten sind zur Erstellung eines 10.000 Bilder umfassenden Datensatz die Verarbeitung von 2500 Stunden Rohvideomaterials aus dem Kraftwerk notwendig. Gegebenenfalls kann der bestehende Trainingsdatensatz durch die sogenannte Image Data Augmentation erweitert werden. Bei dieser Technik werden die vorhandenen Daten durch Pixelverschiebung, Rotation und Zooming bearbeitet, um zusätzliche Trainingsdaten aus den bereits vorhandenen Daten zu generieren. In einer Untersuchung zu dem Thema von Shorten und Khoshgoftaar [SK19] zeigt sich, dass dieser Ansatz helfen kann, die Stabilität eines neuronalen Netzes zu verbessern und das Overfitting zu reduzieren.

4 Diskussion und Ausblick

Aufgrund der Heterogenität des Inputs in die Abfallverbrennungskraftwerke ist es schwierig das Verbrennungsverhalten vorherzusagen. Die Thematik ist extrem komplex und es gibt sehr wenig parallele Forschungsaktivitäten. Auch die Übertragbarkeit von Erkenntnissen aus gängigen Kraftwerken ist aufgrund der Unterschiede in den Brennstoffen nicht möglich. Erschwerend kommt hinzu, dass das vorrangige Ziel der Abfallverbrennungskraftwerke die Abfallbehandlung ist und Emissionsgrenzwerte eingehalten werden müssen. Zukünftig werden Emissionsgrenzwerte weiter verschärft werden, um die Abfallverbrennung noch umweltschonender zu gestalten. Gleichzeitig ist es ein gesellschaftliches Ziel die Effizienz der Rückgewinnung der im Abfall gebundene Energie zu erhöhen, um die Energieversorgung nachhaltiger zu gestalten. Die Kreislaufwirtschaft ist ein unverzichtbarer Bestandteil unserer Gesellschaft und trägt wesentlich zur Erreichung unserer Nachhaltigkeitsziele bei. Abfall muss umweltschonend behandelt werden, damit keine gefährlichen Reststoffe unsere Umwelt schädigen.

Vor diesem Hintergrund ist es notwendig, neue Methoden für die Analyse des Verbrennungsverhaltens des Brennstoffs Abfall zu entwickeln. Methoden aus dem Bereich der Künstlichen Intelligenz sind bisher aufgrund der Heterogenität des Inputmaterials sehr wenig eingesetzt. Wie im Beispiel des Transfer Learnings gezeigt, bieten Bildanalysen von Abfällen großes Potential, um vor der Verbrennung einen Überblick über die zu erwartenden Verbrennungseigenschaften zu generieren. Gleichzeitig zeigt das Beispiel des Transfer Learnings, dass die Entwicklung spezielle auf Abfälle zugeschnittener Methoden erforderlich ist um hier einen signifikanten Beitrag zur Vorhersage leisten zu können. Durch die hier vorgestellte Methodik zur Generierung von Trainingsdaten für ein speziell auf die Bilderkennung von Abfällen zugeschnittenes Neuronales Netz wird ein großer Beitrag zur Entwicklung neuer KI-gestützter Methoden für die Abfallverbrennung geleistet. Die Methodik wird laufend erweitert und trainiert, so dass weitere Ergebnisse in naher Zukunft zu erwarten sind.

5 Literaturverzeichnis

- [Be12] Beckmann, M.; Scholz, R.; Pohl, M. (2012): Bilanzierung und energetische Bewertung von Verfahren zur Abfallbehandlung. In: Energie aus Abfall 9, S. 147–192.
- [Bra00] Bradski G. The OpenCV Library. Dr Dobb's Journal of Software Tools 2000
- [Ch11] Christensen, Thomas H. (Hg.) (2011): Solid Waste Technology & Management. Volume 1 and 2. University of Denmark. Chichester, United Kingdom: Wiley.
- [Cy21] Cyris, F.: Prozessgütemonitoring der Wärmekraftumwandlung von Abfallverbrennungskraftwerken. Dissertation. Leibniz Universität Hannover 2021
- [De13] Decker, F. Altkleidersammlung, 2013, CC-BY-SA-3.0, Lizenz: CC-BY-SA-3.0, <https://de.wikipedia.org/wiki/Datei:Altkleidersammlung.JPG>
- [EE21] EEW Energy from Waste GmbH, eigene Bilder mit freundlicher Genehmigung, 26.4.2021
- [Ge12] Gesetz zur Förderung der Kreislaufwirtschaft und Sicherung der umweltverträglichen Bewirtschaftung von Abfällen (Kreislaufwirtschaftsgesetz - KrWG): KrWG, 2012.[Ho21] Hofstaetter, Pytesseract – A Python wrapper for Google Tesseract, <https://github.com/madmaze/pytesseract>, Stand 27.04.2021
- [Hou21] HOU, Yafei, et al. A Study of Throughput Prediction using Convolutional Neural Network over Factory Environment. In: 2021 23rd International Conference on Advanced Communication Technology (ICACT). IEEE, 2021. S. 429-434.
- [Im21] ImageNet, <http://www.image-net.org/>, Stand 26.04.2021
- [Kr17] Kranert, Martin (2017): Einführung in die Kreislaufwirtschaft. Wiesbaden: Springer Fachmedien Wiesbaden.
- [Ri08] Richtlinie 2008/98/EG des Europäischen Parlaments und des Rats über Abfälle und zur Aufhebung bestimmter Richtlinien, 2008.
- [SK19] Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. Journal of Big Data, 6(1), 1-48.
- [SZ14] Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556.
- [Vo01] Verordnung über die umweltverträgliche Ablagerung von Siedlungsabfällen (Abfallablagerungsverordnung): AbfAbIV, 2001.