



# Energieverbrauch von künstlicher Intelligenz

Softwarelösungen vor dem Hintergrund der digitalen  
Souveränität

---

## Autorin

Janna Axenbeck

## Kurz gesagt

Immer komplexere Modelle und größere Datenmengen erhöhen den Energieverbrauch von künstlicher Intelligenz (KI). Diesbezügliche Transparenz und „grüne“ Standardeinstellungen können den ökologischen Fußabdruck der KI-Nutzung mit wenig Aufwand verringern, ohne dabei die selbstbestimmte Anwendung zu gefährden.

Diese Studie wurde für CO:DINA als Auftragsarbeit erstellt.

## 1. Motivation

Künstliche Intelligenz (KI) und insbesondere das hierzugehörige maschinelle Lernen<sup>1</sup> sind Schlüsseltechnologien der digitalen Transformation. Mit der Anwendung von KI-Systemen hängen jedoch einige Risiken zusammen. Zum Beispiel geraten intransparente Entscheidungsprozesse, die Reproduktion gesellschaftlicher Ungleichheiten sowie die Abhängigkeit von ausländischen Unternehmen als gesellschaftliche und wirtschaftliche Bedrohungen, die von KI-Systemen ausgehen, immer wieder in den Fokus (Fritzsche et al., 2022; Rohde et al., 2021). Nicht ohne Grund ist das Thema künstliche Intelligenz fester Bestandteil in öffentlichen Debatten um digitale Souveränität (Digital Gipfel, 2018, 2020; Fritzsche et al., 2022; Seifried & Bertschek, 2021). Diese bezeichnet die „Summe aller Fähigkeiten und Möglichkeiten von Individuen und Institutionen, ihre Rolle(n) in der digitalen Welt selbstständig, selbstbestimmt und sicher ausüben zu können“ (Goldacker, 2017, S. 3, nach Fritzsche et al., 2022). Voraussetzung hierfür sind u. a. die *Vertrauenswürdigkeit von Kommunikation* und die *Kontrolle über Datenflüsse*. Darüber hinaus wird die Möglichkeit *selbstbestimmt zu handeln und Innovationen durchzuführen* als weitere Grundlage angesehen (Digital Gipfel, 2018, 2020).

Zusätzlich stellen KI-Anwendungen auch eine mögliche Gefahr für das Klima dar. Durch immer komplexer werdende Modelle und wachsende Datenmengen lässt sich ein exponentieller Anstieg der benötigten Rechenleistung beobachten (Amodei & Hernandez, 2018; Schwartz et al., 2019; Sun et al., 2017). Dies erhöht den KI-bedingten Energieverbrauch und abhängig vom Energie-Mix auch die CO<sub>2</sub>-Emissionen (Schwartz et al., 2019; Strubell et al., 2019). Abbildung 1 zeigt das exponentielle Wachstum von Modellparametern und Trainingsdaten in den letzten Jahren am Beispiel von KI-Sprachmodellen.

Ein weiteres Problem, das sich aus dem Wachstum der benötigten Rechenleistung ergibt, ist, dass die Entwicklung komplexer Modelle in den letzten Jahren so teuer wurde, dass sie in vielen Bereichen mittlerweile nur von sehr großen Technologieunternehmen, wie Alphabet oder Meta, vorangetrieben wird. Der wachsende Energiebedarf von KI-Modellen beeinflusst somit auch die

---

<sup>1</sup> In diesem Beitrag wird künstliche Intelligenz synonym zum maschinellen Lernen verwendet, das als computergestütztes Lernen von statistischen Zusammenhängen aus Daten definiert werden kann.

digitale Souveränität, da die Fähigkeit eingeschränkt wird, eigenständig Innovationen durchzuführen.

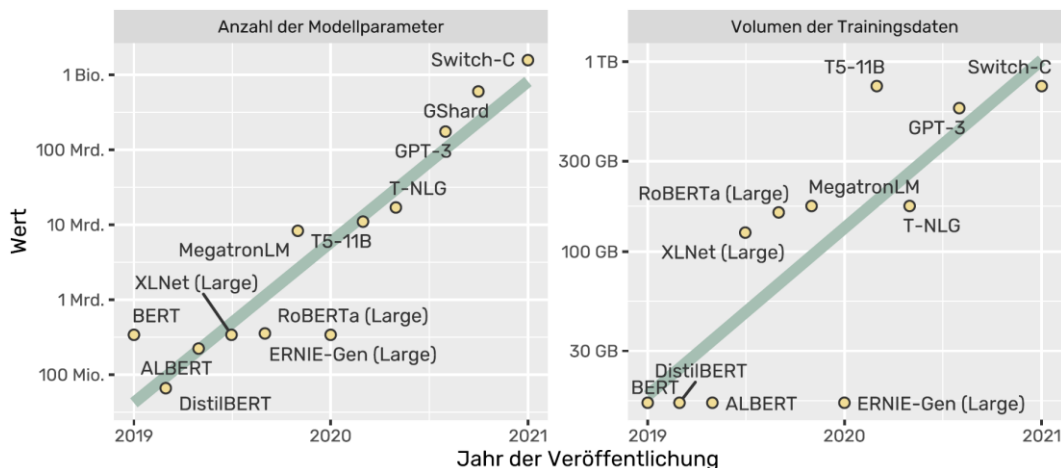


Abbildung 1 Überblick über die Anzahl der Modellparameter und der Größe der verwendeten Trainingsdaten von bekannten Sprachmodellen zwischen 2019 und 2021 (log-skalierte y-Achse; Werte nach Bender et al., 2021).

Um den negativen Folgen von KI-Anwendungen für das Klima entgegenzutreten, formulieren bspw. Anthony et al. (2020), Henderson et al. (2020), Lacoste et al. (2019), Patterson et al. (2021) und Strubell et al. (2019) eine Reihe an Handlungsempfehlungen. Sie sollen es ermöglichen, die Vorteile von künstlicher Intelligenz auf eine klimafreundlichere Weise zu nutzen. Da digitale Souveränität für Individuen, Organisationen, wie öffentliche Verwaltungen oder Unternehmen, und Staaten eine wichtige Säule europäischer Digitalpolitik darstellt (Europäische Kommission, 2022), ist es wichtig zu untersuchen, inwieweit Handlungsempfehlungen zur Verbesserung des KI-bedingten ökologischen Fußabdruckes mit dieser in Wechselwirkung stehen. Im Folgenden wird dabei auf mögliche Softwarelösungen zur Verringerung des Energieverbrauchs von KI-Anwendungen fokussiert. Geringere Kosten durch eine softwaregesteuerte Senkung des Energieverbrauchs können zum Beispiel Eintrittsbarrieren bei der KI-Entwicklung senken (Schwartz et al., 2019; Strubell et al., 2019).

## 2. Handlungsmaßnahmen

Mögliche Softwarelösungen zur Verbesserung der Klimabilanz von KI werden in diesem Abschnitt anhand der vier Handlungsfelder (1) „Komplexität der KI-Modelle“, (2) „Modelltraining, Hyperparameteroptimierung und Modellentwicklung“, (3) „Datenmenge“ und (4) „Transparenz“ genauer

beschrieben und vor dem Hintergrund ihres Einflusses auf die digitale Souveränität bewertet.

## 2.1. Komplexität der KI-Modelle

Die Komplexität eines KI-Modells bemisst sich u. a. durch die Parameteranzahl und bestimmt den mit dem Energieverbrauch zusammenhängenden Rechenaufwand (Schwartz et al., 2019). Die Parameteranzahl von KI-Modellen wächst rapide (siehe Abbildung 1). Oft können jedoch auch weniger komplexe Modelle eine ausreichend genaue Vorhersage erzielen. Anthony et al., 2020; Douwes et al., 2021; Strubell et al. (2019) und Schwartz et al. (2019) empfehlen daher die Energieeffizienz, also das Verhältnis zwischen Energieverbrauch und Vorhersagegenauigkeit, bei der Auswahl von Modellen zu berücksichtigen. Henderson et al. (2020) schlagen in diesem Zusammenhang sogenannte „grüne“ Standardeinstellungen (*Green Defaults*) vor. Das heißt, der Energieeffizienz sollte eine höhere Bedeutung bei der Auswahl von Standardeinstellungen in KI-Softwarelösungen gegeben werden.

*Green Defaults* sind unkompliziert in der Umsetzung, weil Entscheidungen über Standardeinstellungen ohnehin gefällt werden müssen. Zum Beispiel besitzen viele KI-Softwarepakete veränderbare Voreinstellungen, die den Aufbau eines KI-Modells oder die Datenmenge, die in einem Optimierungsschritt berücksichtigt wird, bestimmen. „Grüne“ Standardeinstellungen ermöglichen weiterhin selbstbestimmtes Handeln, da andere, weniger energieeffiziente Konfigurationen immer noch zulässig sind. Sie erlauben es also den Energieverbrauch und die hiermit zusammenhängenden Kosten zu senken, ohne die Handlungsfreiheit von Entwickler\*innen und Anwender\*innen einzuschränken.

Zudem können verschiedene Kompressionsverfahren die Komplexität von Modellen verringern (Li et al., 2021; Yang et al., 2016).<sup>2</sup> Diese beeinflussen aber die Vorhersagekraft des Modells. Da sich diese verschlechtert, könnten hier zu strenge Regelungen die Autonomie von Entwickler\*innen und Anwender\*innen einschränken.

---

<sup>2</sup> Zum Beispiel Pruning oder Quantisierung.

## 2.2. Modelltraining, Hyperparameteroptimierung und Modellentwicklung

Während des Modelltrainings lernt eine KI aus Trainingsdaten statistische Zusammenhänge. Parcollet und Ravanelli (2021) zeigen, dass hiermit oft Ineffizienzen einhergehen, wenn der Trainingsprozess nicht rechtzeitig beendet wird. Denn sobald ein bestimmtes Niveau an Vorhersagegenauigkeit erreicht ist, sind geringfügige Verbesserungen mit extrem hohem Energieaufwand verbunden. Eine Möglichkeit den Energieverbrauch zu verringern, sind daher intelligente Abbruchkriterien, durch die das Training beendet wird, sobald die ökologischen Kosten einen bestimmten Schwellenwert übersteigen (Anthony et al., 2020). Für diesen Schwellenwert ist es jedoch schwierig ein allgemeingültiges Maß zu finden, da der ökologische Fußabdruck gegenüber dem Nutzen der KI-Anwendung abgewogen werden muss. Deswegen wären hier „grüne“ Standardeinstellungen für die Beendigung des Trainings ebenfalls sinnvoll, da dadurch, dass der Schwellenwert bei Bedarf abgeändert werden kann, diese im Gegensatz zu festen Regelungen die Selbstbestimmung nicht zu stark einschränken.

Hyperparameter steuern den Lernprozess von KI-Modellen und müssen vor der Anpassung des Modells definiert werden. Das Verfahren bei dem systematisiert versucht wird, die Hyperparameterkombination mit der besten Vorhersagekraft zu identifizieren, heißt Hyperparameteroptimierung. Der Hyperparameteroptimierung übergeordnet ist die Modellentwicklung. Bei dieser wird meist in einem Trial-and-Error-Verfahren versucht, die Modellkonstruktion mit der höchsten Vorhersagekraft zu identifizieren.<sup>3</sup>

In der Praxis werden bei der Modellentwicklung und auch bei der Hyperparameteroptimierung oft viele sehr ähnliche Modelle immer wieder von neuem trainiert, wodurch hohe Ineffizienzen entstehen können (Parcollet & Ravanelli, 2021; Tornede et al., 2021). Zur Hyperparameteroptimierung gibt es verschiedene Herangehensweisen wie die *Bayesian Search*, die im Vergleich zu der am weitesten verbreiteten *Grid Search* deutlich energieeffizienter ist (Anthony et al., 2020; Strubell et al., 2019). Die *Bayesian Search* ließe sich ebenfalls als „grüne“ Standardeinstellung in Softwarepaketen implementieren.

---

<sup>3</sup> Verschiedene Konstruktionen können unterschiedlich viele Hyperparameter besitzen und sowohl die Modellentwicklung als auch die Kombination der Hyperparameter kann die Modellkomplexität beeinflussen.

Um den Energieverbrauch beim Training und der Modellentwicklung zu reduzieren, bietet sich außerdem das sogenannte *Transfer Learning* an, das sich in den letzten Jahren in verschiedenen Anwendungskontexten etabliert hat. Hierbei werden Modelle, die zuvor einmalig mit einer großen Datenmenge und viel Rechenaufwand angepasst wurden, unter verhältnismäßig geringem Rechenaufwand auf spezifische Kontexte feinabgestimmt (Han et al., 2021). Dieses Vorgehen wird von Schwartz et al. (2019) als "*green success*" bewertet, da die besonders energieintensive Phase des Vortrainings nicht immer wieder neu durchlaufen werden muss. Das *Transfer Learning* fördert zwar einerseits die Fähigkeit zur Innovation, da auf zusätzliche Ressourcen zurückgegriffen werden kann, jedoch erhöht sich hierdurch andererseits die Abhängigkeit von großen (oft ausländischen) Konzernen, die die meisten dieser vortrainierten Modelle entwickeln und veröffentlichen (Strubell et al., 2019).

### 2.3. Datenmenge

Zur Verbesserung der Vorhersagekraft wurden in den letzten Jahren zunehmend größere Trainingsdatensätze verwendet (Schwartz et al., 2019; Strubell et al., 2019 ; siehe Abbildung 1). Dies geht zum einen mit immer komplexeren Modellen einher, die es erlauben, von mehr Trainingsdaten zu profitieren. Zum anderen sind abnehmende Grenzerträge zu beobachten. Das heißt, die Vorhersagekraft steigt nicht proportional zur verwendeten Datenmenge, sondern nur in einem geringeren Umfang (Mahajan et al., 2018; Sun et al., 2017). Eine vorgeschlagene Lösung hierfür ist die Dateneffizienz, also das Prüfen und Berichten ab wie viel Beobachtungspunkten sich die Vorhersagekraft eines KI-Modells kaum verbessert (Schwartz et al., 2019) oder gegebenenfalls sogar verschlechtert (Regneri, 2021). Der Zusammenhang einer solchen Berichterstattung mit digitaler Souveränität wird im Abschnitt „2.4 Transparenz“ diskutiert.

Die Verwendung extrem großer Datenmengen wirkt sich nicht nur negativ auf den Energieverbrauch der Modelle aus, sondern führt außerdem dazu, dass diese ohne Hochleistungsrechner nicht mehr verarbeitet werden können. Hierdurch sind viele Entwickler\*innen von der Nutzung größer Datensätze ausgeschlossen (Schwartz et al., 2019; Strubell et al., 2019). Genau wie bei der Modellentwicklung, schafft hier das *Transfer Learning* Abhilfe, indem bereits vortrainierte Modelle, die mit vielen Daten angepasst wurden, mit verhältnismäßig wenigen Daten für spezifische Anwendungsfälle individuell feinabgestimmt werden können. Neben der bereits erwähnten Abhängigkeit von großen Technologiekonzernen ergibt

sich in Bezug auf das Handlungsfeld „Datenmenge“ ein weiteres Problem beim *Transfer Learning*, da kein Einfluss auf die Datengrundlage des vortrainierten Modells genommen werden kann. Viele Datensätze weisen aber Stichprobenverzerrungen auf und so kann es dazu kommen, dass bspw. diskriminierende Effekte und die Reproduktion von gesellschaftlichen Ungleichheiten bei der Anwendung in Kauf genommen werden müssen (Bender et al., 2021).

## 2.4. Transparenz

Darüber hinaus empfehlen viele Studien ökologische Transparenz durch die Berechnung und Offenlegung des Energieverbrauchs, der CO<sub>2</sub>-Emissionen oder des Rechenaufwandes von KI-Anwendungen (Anthony et al., 2020; Henderson et al., 2020; Lacoste et al., 2019; Strubell et al., 2019).<sup>4</sup> Diese soll das Bewusstsein für die Gefahren von KI für unser Klima schärfen und so Maßnahmen zur deren Abwendung weiter in den Vordergrund rücken (Henderson et al., 2020). Außerdem befürworten viele der Autor\*innen Informationen über die Effizienz von Modellen bereitzustellen, indem bspw. Angaben zum Verhältnis von Rechen-, Energie- oder Datenaufwand zur Vorhersagekraft des Modells gemacht werden. Dies ermöglicht es zwischen ökologischem Fußabdruck und Modelleistung abzuwägen.

Informationen, die mit dem Energieverbrauch zusammenhängen, erlauben es, den eigenen ökologischen Fußabdruck besser kontrollieren zu können und unterstützen dementsprechend selbstbestimmtes Handeln im Digitalen. Nachvollziehbarkeit und Replizierbarkeit von KI-Modellen sind wichtige Kriterien für digitale Souveränität (Digital Gipfel, 2018). Um diese zu gewährleisten, werden meist der Programmcode und Angaben zur Hardware veröffentlicht. Da Rechenaufwand und Energieverbrauch anhand dieser Auskünfte ebenfalls abgeschätzt werden können, müssen hierdurch nicht zwangsläufig neue Informationen preisgegeben werden. Zur Abschätzung der CO<sub>2</sub>-Emissionen werden jedoch zusätzliche Informationen über den Standort benötigt, um den Energie-Mix bestimmen zu können (Henderson et al., 2020; Patterson et al., 2021). Das Offenlegen dieser Information bietet Vorteile für die digitale Souveränität, denn hierdurch lässt sich sicherstellen, dass KI-Modelle an

---

<sup>4</sup> Diesbezügliche Informationen können sowohl die Entwicklung, Anpassung als auch Anwendung eines Modells zur Vorhersage umfassen.

vertrauenswürdigen Orten berechnet wurden. Dies ermöglicht somit eine gewisse Transparenz über Datenflüsse.

Nebenbei ermöglicht die Berechnung des Energieverbrauchs einen Überblick über die KI-bedingten Energiekosten zu gewinnen, wodurch Innovationsanreize durch das Aufzeigen von Ineffizienzen gesetzt werden. Zudem vereinfacht das Teilen von Informationen über den Energieverbrauch die Identifikation „grüner“ Standardeinstellungen. Denn wenn die Faktoren, die den Energieverbrauch bestimmen, besser bekannt sind, lassen sich energieeffiziente Defaults leichter definieren.

Ökologische Transparenz ist leicht zu implementieren, da zur Erfassung der entsprechenden Werte meist nur ein paar Zeilen zusätzlicher Programmcode notwendig sind. Hierfür können zum Beispiel der *Machine Learning Emissions Calculator* von Lacoste et al. (2019), der *Carbontracker* von Anthony et al. (2020), der *Experiment Impact Tracker* von Henderson et al. (2020) oder das Softwarepaket CodeCarbon<sup>5</sup> genutzt werden.

### 3. Impuls für die Umsetzung einer energieeffizienteren und umweltfreundlicheren KI

Aus den beschriebenen softwareseitigen Handlungsempfehlungen stechen zwei besonders heraus: Ökologische Transparenz und „grüne“ Standardeinstellungen. Durch diese lässt sich der ökologische Fußabdruck von KI-Systemen mit geringem Aufwand reduzieren, ohne dabei die selbstbestimmte Anwendung dieser zu gefährden. „Grüne“ Standardeinstellungen können vor allem Anwender\*innen, die sich selten über energieeffizientere Modellkonfigurationen bewusst sind, zu einem geringeren Energieverbrauch verhelfen. Da durch die Veröffentlichung von Energieverbrauch und CO<sub>2</sub>-Emissionen die Klimabilanz von KI-Systemen für verschiedene Stakeholder bekannt wäre, ließe sich hierdurch der Anreiz für Forscher\*innen, Entwickler\*innen und Anwender\*innen erhöhen, diese so weit wie möglich zu verbessern.

Eine Frage, die sich eröffnet, ist, wie sich „grüne“ Standardeinstellungen und ökologische Transparenz durchsetzen lassen. Ohne Zweifel spielen hier Selbstverpflichtungen der Branche eine große Rolle, da es schwierig ist, KI-

---

<sup>5</sup> [www.codecarbon.io/](http://www.codecarbon.io/)



Systeme, die über verschiedene Ländergrenzen hinweg entwickelt und angewendet werden, auf nationaler Ebene zu regulieren. Auf europäischer Ebene bietet sich jedoch hier momentan eine Möglichkeit: Die EU strebt mit der KI-Verordnung (AI Act) einen Rechtsrahmen an, der es erlaubt, KI-Systeme, die eine potenzielle Gefahr für unsere Gesellschaft darstellen, zu regulieren, indem diese anhand ihrer Auswirkungen auf Grundrechte, Sicherheit und Privatsphäre in verschiedene Risikoklassen eingestuft werden. Im AI Act aber bisher unberücksichtigt ist die Einschätzung von KI-Systemen hinsichtlich ihrer Gefahr für das Klima. Da der Klimawandel eine ernstzunehmende Bedrohung darstellt, wäre es jedoch wichtig auch den ökologischen Fußabdruck von KI-Systemen in die Risikoeinschätzung miteinzubeziehen (Climate Change AI, 2021, Ausschuss für Umweltfragen, öffentliche Gesundheit und Lebensmittelsicherheit [des Europäischen Parlaments], 2022). Dies würde zumindest kommerzielle KI-Anwendungen zur ökologischen Transparenz verpflichten und so Forscher\*innen, Entwickler\*innen und Anwender\*innen dazu anhalten, sich mit der ökologischen Effizienz ihrer KI-Systeme und „grünen“ Standardeinstellungen auseinanderzusetzen.

Transparenz und „grüne“ Standardeinstellungen allein werden zwar als Maßnahmen wahrscheinlich nicht ausreichen, um die CO<sub>2</sub>-Emissionen von KI-Systemen auf ein notwendiges Maß zu reduzieren, dennoch würden sie das ökologische Bewusstsein von Forscher\*innen, Entwickler\*innen und Anwender\*innen schärfen. So kann dies den Weg für eine „grüne“ KI ebnen und durch niedrigere Eintrittskosten mehr Forschungsbeiträge von diverseren Gruppen abseits großer Technologiekonzerne ermöglichen.

## 4. Literaturverzeichnis

- Amodei, D. & Hernandez, D. (2018). AI and Compute. *OpenAI*.  
<https://openai.com/blog/ai-and-compute/>
- Anthony, L. F. W., Kanding, B. & Selvan, R. (2020). *Carbontracker: Tracking and Predicting the Carbon Footprint of Training Deep Learning Models*.  
<http://arxiv.org/abs/2007.03051>
- Ausschuss für Umweltfragen, öffentliche Gesundheit und Lebensmittelsicherheit (des Europäischen Parlaments) (2022). *Opinion 2021/0106(COD)*.  
[https://www.europarl.europa.eu/doceo/document/ENVI-AD-699056\\_EN.pdf](https://www.europarl.europa.eu/doceo/document/ENVI-AD-699056_EN.pdf)
- Bender, E. M., Gebru, T., McMillan-Major, A. & Shmitchell, S. (2021). *On the Dangers of Stochastic Parrots: Can Language Models Be Too Big?* FAccT '21: Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency.  
<https://doi.org/10.1145/3442188.3445922>
- Climate Change AI. (2021). *Feedback on the proposed harmonised Rules on Artificial Intelligence*. [https://ec.europa.eu/info/law/better-regulation/have-your-say/initiatives/12527-Artificial-intelligence-ethical-and-legal-requirements/F2665623\\_en](https://ec.europa.eu/info/law/better-regulation/have-your-say/initiatives/12527-Artificial-intelligence-ethical-and-legal-requirements/F2665623_en)
- Digital Gipfel. (2018). *Digitale Souveränität und Künstliche Intelligenz – Voraussetzungen, Verantwortlichkeiten und Handlungsempfehlungen: Plattform Innovative Digitalisierung der Wirtschaft*. Fokusgruppe „Digitale Souveränität in einer vernetzten Gesellschaft“. Berlin/ Nürnberg.  
[https://www.de.digital/DIGITAL/Redaktion/DE/Digital-Gipfel/Download/2018/p2-digitale-souveraenitaet-und-kuenstliche-intelligenz.pdf?\\_\\_blob=publicationFile&v=5](https://www.de.digital/DIGITAL/Redaktion/DE/Digital-Gipfel/Download/2018/p2-digitale-souveraenitaet-und-kuenstliche-intelligenz.pdf?__blob=publicationFile&v=5)
- Digital Gipfel. (2020). *Digitale Souveränität und Resilienz: Voraussetzungen, Treiber und Maßnahmen für mehr Nachhaltigkeit: Digital-Gipfel-Plattform 2 „Innovative Digitalisierung der Wirtschaft“*. Fokusgruppe Digitale Souveränität.  
[https://www.de.digital/DIGITAL/Redaktion/DE/Digital-Gipfel/Download/2020/digitale-souveraenitaet-und-resilienz.pdf?\\_\\_blob=publicationFile&v=10](https://www.de.digital/DIGITAL/Redaktion/DE/Digital-Gipfel/Download/2020/digitale-souveraenitaet-und-resilienz.pdf?__blob=publicationFile&v=10)
- Douwes, C., Esling, P. & Briot, J.-P. (2021). *Energy Consumption of Deep Generative Audio Models*. <http://arxiv.org/abs/2107.02621>
- Europäische Kommission. (2022). *European Commission digital strategy: Next generation digital Commission*. C(2022) 4388 final.  
[https://ec.europa.eu/info/sites/default/files/strategy/decision-making\\_process/documents/c\\_2022\\_4388\\_1\\_en\\_act.pdf](https://ec.europa.eu/info/sites/default/files/strategy/decision-making_process/documents/c_2022_4388_1_en_act.pdf)
- Fritzsche, K., Pohle, J., Bauer, S., Haenel, F. & Eichbaum, F. (2022). *Digitalisierung nachhaltig und souverän gestalten* (CO:DINA - POSITIONSPAPIER N° 10 | Juni 22). <https://codina-transformation.de/wp->

- [content/uploads/CODINA\\_Positionspapier\\_Digitale-Souvera%CC%88nita%CC%88t.pdf](#)
- Goldacker, G. (2017). *Digitale Souveränität*. Kompetenzzentrum Öffentliche IT - Fraunhofer-Institut für Offene Kommunikationssysteme FOKUS. <https://www.oeffentliche-it.de/documents/10181/14412/Digitale+Souver%C3%A4nit%C3%A4t>
- Han, X., Zhang, Z., Ding, N., Gu, Y., Liu, X., Huo, Y., Qiu, J., Yao, Y., Zhang, A., Zhang, L., Han, W., Huang, M., Jin, Q., Lan, Y., Liu, Y., Liu, Z., Lu, Z., Qiu, X., Song, R., . . . Zhu, J. (2021). Pre-trained models: Past, present and future. *AI Open*, 2, 225–250. <https://doi.org/10.1016/j.aiopen.2021.08.002>
- Henderson, P., Hu, J., Romoff, J., Brunskill, E., Jurafsky, D. & Pineau, J. (2020). *Towards the Systematic Reporting of the Energy and Carbon Footprints of Machine Learning*. <http://arxiv.org/abs/2002.05651>
- Lacoste, A., Luccioni, A., Schmidt, V. & Dandres, T. (2019). *Quantifying the Carbon Emissions of Machine Learning*. <https://arxiv.org/abs/1910.09700>
- Li, B., Jiang, X., Bai, D., Zhang, Y., Zheng, N., Dong, X., Liu, L., Yang, Y. & Li, D. (2021). Full-Cycle Energy Consumption Benchmark for Low-Carbon Computer Vision. <https://arxiv.org/abs/2108.13465>
- Mahajan, D., Girshick, R., Ramanathan, V., He, K., Paluri, M., Li, Y., Bharambe, A. & van der Maaten, L. (2018). *Exploring the Limits of Weakly Supervised Pretraining*. <https://arxiv.org/abs/1805.00932>
- Parcollet, T. & Ravanelli, M. (2021). *The Energy and Carbon Footprint of Training End-to-End Speech*. <https://hal.archives-ouvertes.fr/hal-03190119>
- Patterson, D., Gonzalez, J., Le Quoc, Liang, C., Munguia, L.-M., Rothchild, D., So, D., Texier, M. & Dean, J. (2021). *Carbon Emissions and Large Neural Network Training*. <http://arxiv.org/abs/2104.10350>
- Regneri, M. (2021): Datenwert und Datenminimalismus: Wege zu nachhaltiger künstlicher Intelligenz. In: R. Altenburger & R. Schmidpeter (Hrsg.), *CSR und Künstliche Intelligenz*. Springer. [https://doi.org/10.1007/978-3-662-63223-9\\_10](https://doi.org/10.1007/978-3-662-63223-9_10)
- Rohde, F., Wagner, J., Reinhard, P., Petschow, U., Meyer, A., Voß, M. & Mollen, A. (2021). *Nachhaltigkeitskriterien für künstliche Intelligenz: Entwicklung eines Kriterien- und Indikatorensets für die Nachhaltigkeitsbewertung von KI-Systemen entlang des Lebenszyklus* (Schriftenreihe des IÖW 220/21). [https://www.ioew.de/publikation/nachhaltigkeitskriterien\\_fuer\\_kuenstliche\\_intelligenz](https://www.ioew.de/publikation/nachhaltigkeitskriterien_fuer_kuenstliche_intelligenz)
- Schwartz, R., Dodge, J., Smith, N. A. & Etzioni, O. (2019). *Green AI*. <https://arxiv.org/abs/1907.10597>
- Seifried, M. & Bertschek, I. (2021). *Schwerpunktstudie Digitale Souveränität: Bestandsaufnahme und Handlungsfelder*. <https://www.de.digital/DIGITAL/Redaktion/DE/Digitalisierungsindex/Publikatio>

[nen/publikation-download-schwerpunkt-digitale-souveraenitaet-2021.pdf?\\_\\_blob=publicationFile&v=6](#)

Strubell, E., Ganesh, A. & McCallum, A. (2019). *Energy and Policy Considerations for Deep Learning in NLP*. <https://arxiv.org/abs/1906.02243>

Sun, C., Shrivastava, A., Singh, S. & Gupta, A. (2017). *Revisiting Unreasonable Effectiveness of Data in Deep Learning Era*. <https://arxiv.org/abs/1707.02968>

Tornede, T., Tornede, A., Hanselle, J., Wever, M., Mohr, F. & Hüllermeier, E. (2021). *Towards Green Automated Machine Learning: Status Quo and Future Directions*. <http://arxiv.org/abs/2111.05850>

Yang, T.-J., Chen, Y.-H. & Sze, V. (2016). Designing Energy-Efficient Convolutional Neural Networks using Energy-Aware Pruning. <https://arxiv.org/abs/1611.05128>

## 6. Über die Autorin

**Janna Axenbeck**

**ZEW Mannheim**


Janna Axenbeck ist wissenschaftliche Mitarbeiterin im Forschungsbereich "Digitale Ökonomie" am ZEW Mannheim. Hier erforscht sie den Zusammenhang zwischen technologischem Wandel, insbesondere der Digitalisierung, und Nachhaltigkeit mit einem Schwerpunkt auf Energiefragen. Für ihre Analysen setzt sie unter anderem Methoden des maschinellen Lernens ein.

## Über CO:DINA

Das Verbundvorhaben CO:DINA – Transformationsroadmap Digitalisierung und Nachhaltigkeit vernetzt Wissenschaft, Politik, Zivilgesellschaft und Wirtschaft, um neue strategische Stoßrichtungen für eine sozial-ökologische Digitalisierung zu identifizieren. Vielfalt in Denkweisen, Perspektiven und Erfahrungen ist die Voraussetzung, um die Komplexität der Digitalisierung besser zu verstehen und grundlegenden Fragen insbesondere zur Künstlichen Intelligenz mit tragfähigen Lösungsansätzen zu begegnen. Dabei entstehen Netzwerke zwischen Akteursgruppen, die bislang unzureichend verbunden waren. So wird die politische und gesellschaftliche Handlungsfähigkeit für einen sozial-ökologisch-digitalen Wandel gestärkt.

Das Vorhaben wird vom Bundesministerium für Umwelt, Naturschutz, nukleare Sicherheit und Verbraucherschutz (BMUV) im Rahmen der KI-Leuchtturinitiative gefördert und gemeinsam vom IZT – Institut für Zukunftsstudien und Technologiebewertung und dem Wuppertal Institut für Klima, Umwelt, Energie umgesetzt.

Gefördert durch:



aufgrund eines Beschlusses  
des Deutschen Bundestages

## Impressum



IZT – Institut für Zukunftsstudien und  
Technologiebewertung gemeinnützige GmbH  
Schopenhauerstr. 26, 14129 Berlin  
Tel.: +49 (0) 30 803088-0  
Fax: +49 (0) 30 803088-88  
E-Mail: [info@izt.de](mailto:info@izt.de)  
Internet: [www.izt.de](http://www.izt.de)



Wuppertal Institut für Klima, Umwelt, Energie GmbH  
Döppersberg 19, 42103 Wuppertal  
Tel.: +49 (0) 202-2492-101  
Fax: +49 (0) 202-2492-108  
E-Mail: [info@wupperinst.org](mailto:info@wupperinst.org)  
Internet: [www.wupperinst.org](http://www.wupperinst.org)



Weitere Veröffentlichungen unter:

[www.codina-transformation.de](http://www.codina-transformation.de)