


Energieverbrauch und CO₂-Emissionen durch Entwicklung und Anwendung Künstlicher Intelligenz

Überblick und Bewertungsansätze im Projekt X-KIT

Stefan Rilling ¹, Patricia Kelbert², Daniel Martini³, Jens Henningsen², Lorenz Wickert¹, Katharina Milde¹

Abstract: In diesem Beitrag wird auf die Nachhaltigkeit von unterschiedlichen KI-Methoden eingegangen. In den letzten Monaten haben Methoden der Künstlichen Intelligenz eine hohe öffentliche Aufmerksamkeit bekommen und insbesondere die Vorteile für die Nachhaltigkeit benannt. Allerdings müssen in dieser Debatte auch die negativen ökologischen Auswirkungen von KI-Methoden betrachtet werden. In diesem Beitrag wird ein Überblick über verschiedene Ansätze zur Nachhaltigkeitsbewertung vorgestellt und insbesondere Fragestellungen in Bezug auf Energieverbrauch und damit verbundener CO₂-Emissionen adressiert.

Keywords: Emissionen, Energieverbrauch, KI-Modelle, Maschinelles Lernen, CO_{2e}-Verbrauch

1 Einleitung

Durch die Einführung und den Einsatz von Large Language Models (LLMs), wie zum Beispiel ChatGPT hat Künstliche Intelligenz in den letzten Monaten immense öffentliche Aufmerksamkeit auf sich gezogen. Gleichzeitig wurden in der Debatte über Nutzen und Risiken angesichts der für das Training dieser Modelle notwendigen großen Rechen- und Speicherkapazitäten, aber auch zunehmend Fragen zu Energieverbrauch und damit verbundener CO₂-Emissionen aufgeworfen (siehe z.B. [SGM19]). Das BMEL fördert derzeit insgesamt 36 Verbundprojekte im Bereich der Künstlichen Intelligenz in der Landwirtschaft, Ernährung und ländlichen Raum. Diese werden durch das Vernetzungs- und Transfervorhaben X-KIT begleitet. Hier sollen gemeinsam mit den Projekten auch zu oben genannten Effekten des KI-Einsatzes Analysen durchgeführt werden und gegebenenfalls Handlungsempfehlungen und Mitigationsstrategien entwickelt werden. Im Fokus dieses Beitrags liegt eine vertiefte Betrachtung von bereits publizierten Methoden

¹ Fraunhofer Institut für Intelligente Analyse- und Informationssysteme IAIS, Schloss Birlinghoven 1, 53757 Sankt Augustin, {stefan.rilling, lorenz.wickert, katharina.milde}@iais.fraunhofer.de

² Fraunhofer Institut für Experimentelles Software Engineering IESE, Abteilung Data Science, Fraunhofer-Platz 1, 67663 Kaiserslautern, Germany {patricia.kelbert, jens.henningsen}@iese.fraunhofer.de

³ Kuratorium für Technik und Bauwesen in der Landwirtschaft e.V., Digitale Technologien, Bartningstraße 49, 64289 Darmstadt, d.martini@ktbl.de

zur Ermittlung der ökologischen Säule der Nachhaltigkeit, insbesondere im Hinblick auf die Emission von CO₂-Äquivalenten (CO_{2e}) und Klimawirkungen. Einerseits wird der KI von einer Reihe von Akteuren im Umfeld der Entwicklung, der Markteinführung und des Betriebs solcher Systeme ein Beitrag zur Verwirklichung der Sustainable Development Goals (SDGs) der Vereinten Nationen zugeschrieben [Vi20]. Andererseits ist es ebenso unerlässlich, die potenziell negativen Auswirkungen, wie einen erhöhten Ausstoß klimarelevanter Gase durch den Betrieb der notwendigen Infrastruktur, zu berücksichtigen. Zur Infrastruktur von Informations- und Kommunikationstechnologien gehören Rechenzentren und Telekommunikationsnetzwerke. Laut [Bu22] ist dafür im Vergleich von 2010 zu 2019 der Stromverbrauch in Deutschland um 45 Prozent gestiegen. Negative Szenarien prognostizieren, dass der Gesamtstromverbrauch sich bis 2030 verdreifachen kann, wenn keine wirksamen Maßnahmen ergriffen werden.

2 Methoden zur Ermittlung der ökologischen Säule der Nachhaltigkeit

2.1 Grundlagen

Das Themengebiet Nachhaltigkeit ist sehr vielfältig und komplex und umfasst im Wirkungsspektrum ökologische, soziale und ökonomische Aspekte, welche entweder auf Produktebene, auf Ebene einzelner Branchen, Technologien, etc. (Mesoebene) oder volkswirtschaftlicher Ebene betrachtet werden kann. Für die Im Projekt X-KIT durchgeführten Analysen ist eine Betrachtung aller Aspekte nicht umsetzbar, da die hier betrachteten KI-Systeme zum großen Teil den Charakter prototypischer Pionierarbeiten besitzen und noch keine signifikante Durchdringung von landwirtschaftlichen Arbeitsprozessen erreicht haben. Deswegen fokussieren wir uns in diesem Beitrag auf die ökologischen Aspekte der Produktebene mittels einer Lebenszyklusanalyse (LCA), in Anlehnung an [An19].

Die **Ökobilanzierung**, auch Ökobilanz oder Lebenszyklusanalyse (engl. Life Cycle Assessment LCA) fasst die Auswirkungen eines Produktes auf die Umwelt über den gesamten Lebensweg zusammen. Dabei werden alle Prozessschritte und Mengen der Input- und Outputströme erfasst, angefangen von der Herstellung bis zur Nutzung und Entsorgung des Produktes. Die Ökobilanz ist in DIN EN ISO 14040/44 standardisiert [Ro21]. Für eine Ökobilanz werden zuerst das betrachtete Produkt und die betrachteten Systemgrenzen, sowie der Zeitraum der Betrachtung definiert. Anschließend erfolgt die *Sachbilanzierung*. Hier werden alle relevanten Daten gesammelt und anhand definierter Kriterien quantifiziert, wie zum Beispiel Energieverbrauch, Materialien, Emissionen und Abfälle. Daraufhin erfolgt die Wirkungsabschätzung, bei der die Umweltwirkungen des Produktes bewertet werden. Beispiele hierfür sind Treibhausgasemissionen, Versauerungspotenzial und Ökotoxizität des Produktes. Abschließend erfolgt die Auswertung der Ökobilanz, bei der die erhobenen Daten und Ergebnisse analysiert werden. In unterschiedlichen Forschungsbeiträgen wird sich neben der Ökobilanzierung mit der Nachhaltigkeit von KI-Methoden beschäftigt [An19; SGM19; Wy21] Dazu gehören die Optimierung der

Energieeffizienz von Hardwarekomponenten, die Entwicklung grüner Algorithmen, die den Energieverbrauch minimieren, und die Verwendung von spezialisierten Software-Tools, die Analyse und Maßnahmenentwicklung unterstützen.

2.2 Messung des CO₂-Fußabdrucks von (KI-)Algorithmen

Die Messung der CO₂_e-Emissionen von KI-Algorithmen ist eine komplexe Aufgabe, da sie eine umfassende Betrachtung der Hardware-Infrastruktur, der Laufzeitumgebung, des Algorithmus selbst und anderer Faktoren erfordert. Man unterscheidet zwei Herangehensweisen:

1. Energieverbrauchsmessung der Hardware (z.B. Durch Verwendung von Strommessgeräten, um den Energieverbrauch der Hardware zu messen, auf der der KI-Algorithmus ausgeführt wird)
2. Profilierung von Ressourcennutzung (z.B. durch Durchführung von Ressourcenprofilen, um den CPU-, Speicher- und Energieverbrauch während der Ausführung des KI-Algorithmus zu überwachen und zu analysieren)

Innerhalb dieser Ansätze kann auch zwischen dem Energieverbrauch in verschiedenen Phasen unterschieden werden, Im Fall von KI-Anwendungen, besonders in der Entwicklung von Modellen auf Basis maschinellen Lernens bezieht sich dies insbesondere auf den Energieverbrauch beim a) Training (inkl. Datenakquise, Datenaufbereitung, ggfs. Datenannotation) und b) im Betrieb. In der Trainingsphase eines KI-Modells wird die Energie hauptsächlich für intensive Berechnungen und Datenverarbeitung aufgewendet. Dies umfasst nicht nur das eigentliche Training des Modells, sondern auch die Beschaffung von Trainingsdaten, die während der Erhebung und dem ggfs. notwendigen Zusammentragen aus verschiedenen Quellen oft großen Ressourceneinsatz erfordert. Zusätzlich kann die Datenbereinigung und -vorbereitung zeitaufwendig und rechenintensiv sein. Die Emissionen, die mit dieser Phase verbunden sind, hängen von den Energiequellen ab, die in den Rechenzentren verwendet werden, in denen Vorbereitung und Training stattfinden. Der regionale Strommix spielt eine entscheidende Rolle bei der Bestimmung der Kohlendioxidemissionen. Im Betriebsstadium eines KI-Modells, nachdem es erfolgreich trainiert wurde und im Einsatz ist, ist der Energieverbrauch hauptsächlich mit der Inferenz verbunden. Während dieser Phase werden Eingabedaten verarbeitet, um Vorhersagen oder Klassifizierungen zu generieren. Der Energiebedarf ist in der Regel geringer als während des Trainings, da das Modell bereits gelernt hat und keine umfangreiche Berechnung von Gewichtungen und Modellparametern erforderlich ist. Dennoch ist der Betrieb entscheidend, da er oft über längere Zeiträume hinweg stattfindet, und auch hier sind die Emissionen von der Art der genutzten Energie abhängig. In Regionen, in denen der Strom hauptsächlich aus erneuerbaren Energien gewonnen wird, ist der CO₂-Fußabdruck geringer als in Regionen, die auf fossile Brennstoffe zur Stromerzeugung angewiesen sind. Daher ist die Kenntnis des Strommixes, in dem eine KI-Anwendung betrieben wird, von großer Bedeutung für die genaue Berechnung ihres Carbon Footprint. Es existieren spezialisierte Software-Tools, die dazu dienen, den

Energieverbrauch von Anwendungen auf der Hardware-Ebene detailliert zu analysieren. Diese Tools erfüllen unterschiedliche Zwecke, und es kann zwischen den "Carbon Footprint Calculators" und Diensten zur nachträglichen Schätzung des CO₂-Fußabdrucks unterschieden werden. Die "Carbon Footprint Calculators" wie beispielsweise CodeCarbon, Experiment-impact-tracker, CarbonTracker und eco2AI⁴ sind darauf ausgerichtet, den Energieverbrauch und die Kohlenstoffemissionen direkt bei der Ausführung von Anwendungen zu quantifizieren. Sie bieten Einblicke in den spezifischen Energiebedarf von Software und ermöglichen es, den Carbon Footprint in Echtzeit zu überwachen. Diese Tools eignen sich besonders gut, um den ökologischen Fußabdruck ihrer Software während der Entwicklung und im laufenden Betrieb zu berücksichtigen. Zusätzlich zu diesen Echtzeit-Tools gibt es Dienste zur nachträglichen Schätzung des CO₂-Fußabdrucks von KI-Anwendungen, wie zum Beispiel ML CO₂ Impact⁵. Diese Dienste analysieren die Umweltauswirkungen von bereits entwickelten Anwendungen oder Modellen. Sie nutzen Daten über die Energieeffizienz von Hardware und den regionalen Strommix, um eine Schätzung des Carbon Footprint auf Grundlage der bekannten oder erfassten Parameter vorzunehmen. Dies ermöglicht eine retrospektive Analyse und kann genutzt werden, um bestehende Anwendungen zu optimieren und den ökologischen Fußabdruck zu reduzieren. Große Cloud-Service-Anbieter wie AWS, Azure und Google Cloud bieten ebenfalls Tools und Dashboards an, die Einblicke in den Energieverbrauch und den CO₂-Fußabdruck von KI-Workloads auf ihren Plattformen liefern. Diese Ressourcen ermöglichen es den Nutzern, den Energieverbrauch ihrer Cloud-basierten KI-Anwendungen zu überwachen und zu verstehen, wie sie ihre Umweltauswirkungen minimieren können. Die Tools der Cloud-Anbieter sind von besonderer Bedeutung, da viele KI-Anwendungen in Cloud-Umgebungen gehostet werden, und die Kenntnis des Carbon Footprint auf diesen Plattformen einen entscheidenden Beitrag zur Nachhaltigkeit leisten kann. Neben den genannten Diensten und Werkzeugen gibt es auch eine Reihe von international anerkannten Datenbanken für Ökobilanzen mit umfassenden Informationen über die Umweltauswirkungen von Produkten und Dienstleistungen über deren gesamten Lebenszyklus hinweg. Im Kontext der Arbeiten in X-KIT sind dabei speziell Datenbanken für den IKT-Bereich von Relevanz. Hier sind exemplarisch die Datenquellen des Projektes Boavizta⁶, welche eine große Emissionsdatenbank für Endgeräte bekannter Technologiemarken zur Verfügung stellen, oder der kommerzielle Anbieter Ecoinvent⁷ zu nennen.

3 Weiteres Vorgehen und Ausblick

Im Vernetzungs- und Transferprojekt X-KIT werden die methodischen Entwicklungen aufgegriffen und methodische Fallstricke, Ergebnisse und ihre Interpretation in

⁴ Links zu den genannten Tools: <https://codecarbon.io/>; <https://github.com/Breakend/experiment-impact-tracker>; <https://github.com/lfwa/carbontracker>; <https://doi.org/10.1134/S1064562422060230>

⁵ <https://mlco2.github.io/impact/>

⁶ <https://github.com/Boavizta/environmental-footprint-data>

⁷ <https://ecoinvent.org/>

Workshops mit den KI-Projekten diskutiert. Überwiegend beziehen sich die ökologischen Kriterien von KI-Anwendungen auf die THG-Emissionen, die durch den Energieverbrauch verursacht werden und die in erster Linie zum Klimawandel beitragen. Diese Emissionen entstehen wie oben dargestellt sowohl beim Training als auch im Betrieb und hängen von verschiedenen Faktoren ab, wie zum Beispiel dem Strommix und der Anzahl der Parameter des verwendeten KI-Modells. Diese Kriterien werden über den Lebenszyklus einer KI-Anwendung im Rahmen der Sachbilanzierung untersucht. Der Lebenszyklus einer KI-Anwendung umfasst dabei gemäß dem oben skizzierten Phasenmodell:

1. **Modellentwicklung:** In dieser Phase wird das KI-Modell entwickelt, das später für die Aufgabe verwendet werden soll. Dies beinhaltet die Auswahl der richtigen Architektur und die Implementierung des Modells.
2. **Datenakquise und Aufbereitung:** Hier werden die benötigten Trainingsdaten beschafft, aufbereitet, und im Falle von überwachten Lernverfahren annotiert.
3. **Training:** Im Training wird das Modell mit Hilfe von Trainingsdaten trainiert, getestet und validiert.
4. **Inferenz:** Nachdem das Modell trainiert wurde, kann es für die Inferenz verwendet werden. Dies bedeutet, dass das Modell auf neue, unbekannte Daten angewendet wird, um Vorhersagen oder Entscheidungen zu treffen.

Für die Erstellung einer Sachbilanz der Phasen Modellentwicklung und Datenakquise ist unser Ansatz die Betrachtung der involvierten menschlichen Arbeitszeit. Diese Lebenszyklusphasen umfassen einen hohen Anteil menschlicher Arbeit, sowohl für die Modellentwicklung als auch für die Annotation der Trainingsdaten, und diese Arbeit wird überwiegend mittels Computer durchgeführt. Da diese Art Arbeit vergleichbar mit typischer Büroarbeit ist, können z.B. Faktoren wie der Stromverbrauch durch den Betrieb der Rechner berücksichtigt werden. Weiterhin entstehen bei der Herstellung der Büroausrüstung ebenfalls Treibhausgasemissionen, die in die Sachbilanzierung anteilmäßig einfließen können. Im Bereich der Datenakquise sind hier die THG-Emissionen beim Betrieb des Akquise Systems (z.B. Kameras oder Sensorsysteme) zu berücksichtigen. Weiterhin entstehen THG-Emissionen bei der Herstellung des Akquise Systems, diese sollten auch in die Sachbilanzierung einbezogen werden. Werden bereits trainierte, verfügbare KI-Modelle verwendet, so müssen diese THG-Emissionen anteilmäßig auf die konkret zu untersuchende Anwendung umgelegt werden. Da in der Regel sowohl die Anzahl der weltweit betriebenen Instanzen eines bestimmten Modells als auch die Energieverbräuche beim Training oft nicht bekannt sind, kann dies sehr schwierig, bzw. unmöglich abzuschätzen sein. Einen Sonderfall stellen hier KI-Systeme, die mit Transferlernen trainiert werden, dar: Hier können die Stromverbräuche, die durch den Transferlernprozess entstehen in der Regel gut gemessen oder abgeschätzt werden, so dass hier eine aussagekräftige Sachbilanz erstellt werden kann. In der Phase der Inferenz, also der Anwendung des Modells auf neue Daten, entstehen THG-Emissionen durch den Stromverbrauch im Betrieb. Hierbei ist es wichtig das gesamte integrierte System zu betrachten. In der Regel sind KI-Systeme nicht isoliert, sondern bestehen aus einer Reihe

weiterer Komponenten zur Kontrolle und Datenverwaltung. Der Betrieb dieser Komponenten kann z.B. auf Dauer größere Mengen an Energie verbrauchen als das eigentliche Training der KI-Komponenten [Pa22], dies gilt insbesondere dann, wenn große Serverinfrastrukturen vorgehalten werden müssen. Auch die Herstellung des integrierten Systems trägt zur THG-Emission bei und muss entsprechend berücksichtigt werden. Die Lebenszyklusanalyse ermöglicht es die Umweltauswirkungen eines Produkts oder Systems über dessen gesamten Lebenszyklus hinweg zu bewerten. Wir haben uns in unserer Arbeit in X-KIT bewusst auf die "Ausgaben"-Seite konzentriert, also auf die THG-Emissionen, die durch den Einsatz von KI-Methoden entstehen können. Einsparungspotentiale durch den Einsatz von KI wurden nicht berücksichtigt. Eine verlässliche Quantifizierung dieser Einsparungen setzt umfangreiche Feldversuche und die Erhebung spezifischer Daten und Analysen voraus. Um solche großangelegten Studien durchzuführen, werden großflächig einsetzbare KI-Systeme mit einem hohen Technologiereifegrad benötigt. Unser Ziel war es daher, einen Überblick über den Themenkomplex zu geben und als Ausgangspunkt für weitere Forschung und Projekte zur Bewertung der Nachhaltigkeit von KI-Systemen zu dienen.

Literaturverzeichnis

- [An19] Lisa Andes; Thomas Lützkendorf; Jürgen Kopfmüller; Christine Rösch (2019): Methodensammlung zur Nachhaltigkeitsbewertung. Grundlagen, Indikatoren, Hilfsmittel. Karlsruher Institut für Technologie KIT; online verfügbar unter: <https://www.ioew.kit.edu/downloads/Methodensammlung%20zur%20Nachhaltigkeitsbewertung.pdf>, zuletzt besucht am 25.10.2023
- [Bu22] Bundestag, Deutscher (2022): Drucksache 20/3650 - Technikfolgenabschätzung (TA) Energieverbrauch der IKT-Infrastruktur. Online verfügbar unter: <https://dserver.bundestag.de/btd/20/036/2003650.pdf>, zuletzt besucht am: 26.10.2023
- [Pa22] Patterson, David; Gonzalez, Joseph; Le, Quoc; Liang, Chen; Munguia, Lluis-Miquel; Rothchild, Daniel; So, David; Texier, Maud and Dean, Jeff (2021): Carbon Emissions and Large Neural Network Training. In Computer (Volume: 55, Issue: 7, July 2022). DOI: 10.1109/MC.2022.3148714
- [Ro21] Rohde, Friederike; Wagner, Josephin; Reinhard, Philipp; Petschow, Ulrich; Meyer, Andreas; Voß, Marcus; Mollen, Anne (2021): Nachhaltigkeitskriterien für künstliche Intelligenz. Erschienen in: IÖW-Schriftenreihe 220/21 (online verfügbar unter https://www.ioew.de/publikation/nachhaltigkeitskriterien_fuer_kuenstliche_intelligenz
- [SGM19] Strubell, Emma; Ganesh, Ananya; McCallum, Andrew (2019): Energy and Policy Considerations for Deep Learning in NLP. Available online at <https://arxiv.org/pdf/1906.02243.pdf>.
- [Vi20] Vinuesa, Ricardo; Azizpour, Hossein; Leite, Iolanda; Balaam, Madeline; Dignum, Virginia; Domisch, Sami et al. (2020): The role of artificial intelligence in achieving the Sustainable Development Goals. In Nature communications 11 (1), p. 233. DOI: 10.1038/s41467-019-14108-y

- [Wy21] van Wynsberghe, Aimee (2021): Sustainable AI: AI for sustainability and the sustainability of AI. In *AI Ethics* 1 (3), pp. 213–218. DOI: 10.1007/s43681-021-00043-6.