

# Swiss PV Circle

## Arbeitspaket 3 – Forecasting

### Forecasting und Visualisierung des End-of-Life-Volumens von PV-Anlagen (2000–2050) inklusive Merkmale- und Altersanalyse

Arbeitspaket-Nummer	AP3
Arbeitspaket-Titel	Forecasting
Arbeitspaket-Lead	Berner Fachhochschule
Deliverable-Nummer	AP3-1
Deliverable-Name	Forecasting und Visualisierung des End-of-Life-Volumens von PV-Anlagen (2000–2050) inklusive Merkmale- und Altersanalyse
Status	Finaler Bericht
Autorin	Ässia Boukhatmi
Verbreitungsebene	Öffentlich
Veröffentlichungsdatum	16.06.2025

## Inhalte

Executive Summary	2
1. Einführung	3
2. Verwendete Methoden	4
2.1 Datenerhebung	4
2.2 Datenaufbereitung	5
2.3 Datenanalyse	5
2.3.1 Qualitative Untersuchung	5
2.3.2 Quantitative Untersuchung	5
Kaplan-Meier Überlebensanalyse	5
Polynomiale Regression	6
Logistische Regression	7
3. Ergebnisse	7
3.1 Merkmalsausprägungen EoL-Anlagen	7
3.2 Alter von EoL-PV-Anlagen	11
3.3 Forecasting der EoL-Mengen bis 2050	11
3.3.1 Forecasting mittels SENS-Abholmengen	11
3.3.2 Forecasting mittels EoL-Classification	12
3.3.3 Vergleich mit bestehenden Studien	14
Forecast Studie IRENA und Wambach Consulting (2022)	14
Forecast Czajkowski et al. (2022)	15
4. Diskussion der Ergebnisse	17
5. Ausblick und Fazit	18
Anhang	19
Literatur	19

## Executive Summary

Der rasche Ausbau der Photovoltaik (PV) im Rahmen der Energiewende wird voraussichtlich zu einem erheblichen Anstieg der Altmodule führen. Um die wachsenden Abfallströme zu bewältigen und die Ressourceneffizienz zu fördern, stellt die Kreislaufwirtschaft ein Wirtschaftsmodell dar, das auf die Schaffung zirkulärer Materialströme abzielt. Obwohl 50% der PV-Module nach ihrem ersten Lebenszyklus technisch wiederverwendbar sind, ist nur wenig über das Alter der End-of-Life-(EoL)-Module und die Faktoren bekannt, die zur Stilllegung oder zum Austausch des Systems führen, wodurch Kreislaufaktivitäten behindert werden. Daher wurden im Rahmen des Swiss PV Circle Projekts innerhalb des Arbeitspakets 3 analytische Ansätze und Daten aus verschiedenen Quellen verwendet, um die Vorhersage für Kreislaufaktivitäten zu verbessern. Da die Datengrundlage zu effektiven EoL-Mengen der vergangenen Jahre noch sehr gering ist, wurde sich zunächst auf die Abholmengen von SENS eRecycling aus den vergangenen Jahren gestützt, um Einsicht in eine zukünftige Entwicklung der Abfallmengen zu erhalten. Diese Zahl wurde in einem zweiten Schritt mit Ergebnissen aus bestehenden wissenschaftlichen Studien verglichen, um aktuelle Annahmen zur Berechnung von Forecasts besser zu verstehen.

Weiter wurden mittels qualitativer Analyse mehr als 500 EoL-Anlagen auf verschiedene Parameter untersucht, um ein besseres Verständnis über die Merkmalsausprägungen der aktuellen Rücklaufmengen zur Verbesserung von Wiederverwendungspraktiken zu ermöglichen. Schliesslich wurden diese EoL-Anlagen als Grundlage für eine wissenschaftliche Studie verwendet, um Erkenntnisse über das Alter und die Machine-Learning (ML)-basierte Klassifizierung von EoL-Anlagen zu erlangen. In einem dritten Schritt wurde das ML-Modell für die Identifikation weiterer EoL-Anlagen im bestehenden Datensatz angewendet, um das Forecasting weiter zu konkretisieren.

Dieser Bericht ist wie folgt aufgebaut: Zunächst wird die Ausgangslage beschrieben, gefolgt von den verwendeten Methoden zur Datenerhebung und Analyse. Danach werden die Ergebnisse aus den verschiedenen Ansätzen vorgestellt und mit bestehenden Studien verglichen. Abschliessend werden die Ergebnisse diskutiert und die wichtigsten Erkenntnisse nochmals zusammengefasst, gefolgt von einem abschliessenden Fazit und einem Ausblick in die Zukunft.

## 1. Einführung

Forecasting bezeichnet die systematische Vorhersage zukünftiger Entwicklungen oder Ereignisse auf der Grundlage historischer Daten, aktueller Trends und relevanter Einflussfaktoren.<sup>1</sup> Im Kontext von EoL-Strömen bezieht sich Forecasting auf die Prognose der Menge, Zusammensetzung und des zeitlichen Auftretens von Produkten, die das Ende ihres Lebenszyklus erreicht haben und für Wiederverwendung, Recycling oder Entsorgung bereitstehen. Dabei kommen verschiedene Methoden zum Einsatz, z. B. statistische Modelle, zeitreihenbasierte Verfahren, Machine Learning Ansätze oder szenariobasierte Projektionen, die das Ziel verfolgen, fundierte Entscheidungen für das Abfallmanagement, die Kreislaufwirtschaft und die Ressourcenplanung zu ermöglichen.

Der entscheidende Faktor, um ein Forecasting zu ermöglichen, sind die hierfür zur Verfügung stehenden Daten. Dabei gelten folgende Grundvoraussetzungen<sup>2</sup>:

- **Historische Daten:** Vergangene Entwicklungen sind oft eine Grundlage für Prognosen. Diese Daten müssen ausreichend lang, zuverlässig und präzise sein.
- **Datenqualität:** Fehlende Werte, Ausreisser und Inkonsistenzen sollten erkannt und gegebenenfalls bereinigt werden.
- **Relevanz der Daten:** Die verwendeten Daten müssen für das zu prognostizierende Phänomen repräsentativ sein.

Weiterhin sollten die relevanten Einflussfaktoren identifiziert werden, die das prognostizierte Ereignis bestimmen. Dazu zählen beispielsweise technologische Entwicklungen, gesetzliche Rahmenbedingungen und Markttrends. Ebenso ist die Wahl eines geeigneten Prognosemodells entscheidend, das von der Art der Daten und dem Ziel der Vorhersage abhängt. Ein weiteres wichtiges Kriterium ist die Stabilität und die Erkennung von Mustern in den historischen Daten. Prognosen sind vor allem dann zuverlässig, wenn wiederkehrende Trends oder saisonale Effekte erkennbar sind; bei stark volatilen Prozessen hingegen ist die Prognosegenauigkeit eingeschränkt. Da jede Prognose Unsicherheiten beinhaltet, sollten diese quantifiziert und kommuniziert werden – beispielsweise durch Konfidenzintervalle oder Szenarioanalysen. Szenariobasierte Prognosen sind besonders sinnvoll, wenn mehrere unsichere Einflussfaktoren eine Rolle spielen. Schliesslich ist eine kontinuierliche Validierung der Prognosen notwendig, um Abweichungen zu erkennen und das Modell bei Bedarf anzupassen. Änderungen im Umfeld, wie technologische Neuerungen, sollten regelmässig in künftige Vorhersagen einfließen<sup>3</sup>.

Diese Grundvoraussetzungen zeigen, dass ein Forecasting vor allem von der Qualität der Daten und der zur Verfügung stehenden Informationen abhängt. Häufig sind jedoch in der Realität Datenquellen fragmentiert, inkonsistent und benötigen einen hohen Aufwand für die Qualitätssicherung. Aus diesem Grund sind mehrere Schritte und Teilprozesse notwendig, um ein Forecasting zu ermöglichen.

Erste Studien für das Forecasting von PV-Abfallmengen wurden bereits in der Vergangenheit erstellt<sup>4</sup>, jedoch sind diese Studien veraltet und berufen sich auf Kennzahlen aus einem limitierten geografischen Kontext zur

---

<sup>1</sup> Makridakis, Wheelwright, and Hyndman, "Forecasting."

<sup>2</sup> Makridakis, Wheelwright, and Hyndman; Goodwin et al., "Principles of Forecasting."

<sup>3</sup> Hyndman and Athanasopoulos, *Forecasting*.

<sup>4</sup> Forti, Baldé, and Kuehr, "E-Waste Statistics"; Rabaia, Semeraro, and Olabi, "Recent Progress towards Photovoltaics' Circular Economy"; Magalani et al., "Study on Collection Rates of Waste Electrical and Electronic Equipment"; Weckend, Wade, and Heath, "End of Life Management."

Erarbeitung der Ergebnisse. Weitere Studien (beispielsweise <sup>5</sup>) stützen sich auf verallgemeinerte Grundannahmen, die es zu verstehen und hinterfragen gilt. Im weiteren Verlauf dieses Berichts wird näher auf diese Studien eingegangen.

## 2. Verwendete Methoden

Nachfolgend werden die im Projekt verwendeten Datenerhebungs- und Analysemethoden vorgestellt. Erstens wurden Abholdaten von SENS eRecycling aus den letzten Jahren genutzt, um eine erste Einschätzung für die Prognose künftiger Abfallmengen mittels polynomialer Regression zu schaffen. Zweitens wurden diese Daten mit Ergebnissen aus wissenschaftlichen Studien verglichen, um die Berechnungsannahmen zu validieren. Drittens erfolgte eine explorative qualitative Analyse von über 500 EoL-Anlagen, bei der verschiedene Parameter untersucht wurden, um ein besseres Verständnis für die Merkmale der Rücklaufmengen zu gewinnen. Ein viertes Element der Studie war die Anwendung von statistischen Modellen (Kaplan-Meier-Analyse und Logistic Regression Modell), die es ermöglichten, das Alter der Anlagen zu bestimmen und EoL-Anlagen zu klassifizieren. Zukünftig soll der Ansatz zur ML-basierten Identifikation weiterer EoL-Anlagen im Datensatz erweitert werden, um die Forecasting-Modelle zu präzisieren.

### 2.1 Datenerhebung

Die für diese Studie verwendeten Daten stammten aus vier Hauptquellen. Erstens haben wir einen öffentlichen Datensatz des Portals Opendata.Swiss verwendet, welcher regelmässig vom Bundesamt für Energie (BFE) herausgegeben wird. Der Datensatz enthält die im Schweizer Herkunftsnachweissystem registrierten Stromproduktionsanlagen mit Standort, Installationsdatum, installierter Leistung und PV-Anlagentyp. Bis Ende 2023 umfasste dieser Datensatz rund 225'000 PV-Anlagen mit einem Alter zwischen 0 und 35 Jahren <sup>6</sup>.

Die zweite, nicht-öffentliche Datenquelle, die vom BFE im Rahmen des Projekts „Swiss PV Circle“ zur Verfügung gestellt wurde, umfasst 15 Zeiterienendatensätze, die die monatliche Energieproduktion jeder PV-Anlage zwischen 2009 und 2023 aufzeichnen. Eine weitere nicht-öffentliche Quelle, die vom Schweizer Rücknahmesystem SENS eRecycling und Partner des Swiss PV Circle Projekts zur Verfügung gestellt wurde, umfasst alle Abholaufträge von 2017 bis Juni 2024, die von Unternehmen oder Sammelstellen für die Abholung und das Recycling von EoL-PVs angefordert wurden <sup>7</sup>. Der Datensatz enthält die Abholadresse, das Datum, die Menge (kg), den PV-Paneltyp, den Modulzustand und den EoL-Grund jedes Abholauftrags. Zusätzlich zu den Abholaufträgen wurden die aggregierten Abholmengen der Jahre 2015 – 2023 zur Verfügung gestellt. Beispielsweise betrug die Gesamtmenge an abgeholteten EoL-PV-Modulen im Jahr 2023 1'000 Tonnen (t).

Als vierte Datenquelle wurde ein Datensatz des SPF-Instituts für Solartechnik einbezogen, der Aufzeichnungen über Hagelschäden an PV-Anlagen in der Schweiz im Jahr 2021 enthält, was zur Identifizierung weiterer ausgedienter PV-Anlagen beitrug. Ergänzend zu diesen vier primären Datenquellen

---

<sup>5</sup> Czajkowski et al., „Prediction of the Market of End-of-Life Photovoltaic Panels in the Context of Common EU Management System.“

<sup>6</sup> Opendata.Swiss, „Electricity Production Plants - Opendata.Swiss.“

<sup>7</sup> SENS eRecycling, „Recyclingsystem von Photovoltaik in der Schweiz.“

nutzten wir historische Bilder von Google Earth Pro, um die EoL-Vorkommen zu verifizieren und die Entwicklung eines umfassenden Datensatzes zu unterstützen.

## 2.2 Datenaufbereitung

Um eine umfassende Datenbasis für PV-Altanlagen zu schaffen, begannen wir mit der Zusammenführung von Datenquellen, hauptsächlich unter Verwendung von Adressen oder Produktidentifikatoren, um eindeutige PV-Anlagen in den Datensätzen zu verknüpfen und zu referenzieren. Dieser Prozess erforderte eine umfangreiche Datenbereinigung und -aufbereitung, um Datensätze mit Lücken zu entfernen, die durch inkonsistente Datenverfolgung in den verwendeten Quellen verursacht wurden, was zu einem unvermeidlichen Verlust von unvollständigen Datenpunkten führte. Die Zusammenführung dieser Quellen ermöglichte es uns auch, zusätzliche EoL-PV-Anlagen zu identifizieren und die vorhandenen Daten durch einen iterativen Querverweisprozess zu ergänzen, um die Glaubwürdigkeit und Vollständigkeit zu verbessern<sup>8</sup>. Auf diese Weise konnten wir 522 EoL-PV-Anlagen und insgesamt ca. 157'000 PV-Anlagen identifizieren, die alle relevanten Informationen für die weitere Datenanalyse enthielten. Der verwendete Datensatz zu EoL-PV-Anlagen stellt jedoch nur eine Stichprobe, aber nicht die Gesamtheit aller bestehenden PV-Anlagen mit EoL-Vorkommen dar.

## 2.3 Datenanalyse

Durch die erheblichen Einschränkungen in den zur Verfügung stehenden Daten, vor allem hinsichtlich der EoL-Anlagen und Mengen sind mehrere Schritte notwendig, um ein Forecasting zu ermöglichen. Nachfolgend werden die Datenanalysetechniken beschrieben, welche bisher im Rahmen des AP3 verwendet wurden, um verbesserte Aussagen über EoL-Anlagen zu ermöglichen. Wie oben angeführt sind weiterhin retrospektive Betrachtungen ein wichtiger Grundbaustein, um einen Blick in die Zukunft zu ermöglichen, weshalb einige Analysen kein klassisches Forecasting umfassen, sondern für eine Beschreibung des aktuellen Ist-Zustands dienen.

### 2.3.1 Qualitative Untersuchung

Als zusätzlichen Schritt verwendeten wir einen explorativen qualitativen Ansatz, um die Merkmalsausprägungen von PV-Anlagen zu untersuchen, die das Ende ihrer Betriebsdauer erreicht haben<sup>9</sup>. Diese Analyse beinhaltet unter anderem die Untersuchung des Grundes für die Stilllegung, des Installationsjahres, der installierten Leistung (kWp) und der geografischen Verteilung von EoL- und aktiven Anlagen. Da die Ergebnisse dieser qualitativen Analyse Gegenstand einer weiteren wissenschaftlichen Studie sein sollen, werden die Ergebnisse aggregiert vorgestellt.

### 2.3.2 Quantitative Untersuchung

#### *Kaplan-Meier Überlebensanalyse*

Als nächstes wurde eine Kaplan-Meier-Überlebenskurve angewendet, welche eine nichtparametrische statistische Methode zur Schätzung von Überlebenswahrscheinlichkeiten im Zeitverlauf durch Untersuchung verschiedener Zeitintervalle darstellt<sup>10</sup>. Der Kaplan-Meier-Schätzer, der auch als

---

<sup>8</sup> Patton, "Enhancing the Quality and Credibility of Qualitative Analysis."

<sup>9</sup> Thomas, "A General Inductive Approach for Qualitative Data Analysis."

<sup>10</sup> Altman, *Practical Statistics for Medical Research*.

„Produktgrenzenschätzung“ bekannt ist, berechnet Überlebenswahrscheinlichkeiten, indem er die Wahrscheinlichkeit des Eintretens eines Ereignisses zu jedem spezifischen Zeitpunkt bestimmt. Obwohl der Kaplan-Meier-Schätzer vorwiegend in der medizinischen Forschung eingesetzt wird, wurde er bereits in Zuverlässigkeitsstudien zur Schätzung der Produktüberlebenswahrscheinlichkeit verwendet <sup>11</sup>. Aufgrund ihrer Anpassungsfähigkeit ist diese Methode für unsere Studie demnach gut geeignet, da sie robuste Schätzungen der Überlebenszeiten für EoL-PV-Systeme liefert und gleichzeitig zensierte Daten berücksichtigt <sup>12</sup>. Zensierte Daten beziehen sich auf Beobachtungen, bei denen das interessierende Ereignis (z. B. EoL) während des Beobachtungszeitraums nicht eingetreten ist, wobei davon ausgegangen wird, dass diese Systeme für das Ereignis „gefährdet“ bleiben <sup>13</sup>. Diese Annahme passt zu unserer Studie, da sie „gefährdete“ PV-Anlagen berücksichtigt, bei denen ein EoL-Ereignis mangels verfügbarer Informationen über die Gesamtheit der EoL-Ereignisse nicht definitiv zugeordnet werden konnte. Die Überlebenswahrscheinlichkeit  $S(t)$  zu einem bestimmten Zeitpunkt ( $t$ ) wird geschätzt durch:

$$\hat{S}(t) = \prod_{i:t_i \leq t} \left(1 - \frac{d_i}{n_i}\right)$$

wobei  $d_i$  die Anzahl der Ereignisse (z. B. Systemausfälle) ist, die zum Zeitpunkt  $t_i$  auftreten und  $n_i$  die Anzahl der „gefährdeten“ Anlagen unmittelbar vor  $t_i$  bezeichnet. Für jedes Zeitintervall werden die Überlebenswahrscheinlichkeiten abgeleitet, indem die Anzahl der betriebsbereiten PV-Anlagen durch die Gesamtzahl der „gefährdeten“ Anlagen geteilt wird. Die kumulative Überlebenswahrscheinlichkeit über einen bestimmten Zeitraum wird dann durch Anwendung des Multiplikationsgesetzes berechnet, wobei die Überlebenswahrscheinlichkeiten aus allen vorangegangenen Intervallen kombiniert werden.

### *Polynomiale Regression*

Für eine erste Einschätzung möglicher EoL-Mengen in den kommenden Jahren wurde eine polynomiale Regression verwendet, um nichtlineare Zusammenhänge zwischen einer oder mehrerer Variablen zu beschreiben. Die Polynomiale Regression ermöglicht eine differenziertere und genaue Modellierung komplexer Trends und ist daher für die Berechnung der sich im Laufe der Zeit entwickelnden EoL-Mengen geeignet. Der Zusammenhang zwischen der unabhängigen Variable  $x$  und der abhängigen Variable  $y$  ergibt sich aus:

$$y = b_0 + b_1x + b_2x^2 + \dots + b_nx^n + e, \text{ wobei}$$

$b$  = Koeffizienten

$e$  = Error term

Als Basis für diese erste Abschätzung wurden die Abholmengen von SENS eRecycling aus den vergangenen Jahren seit 2015 verwendet. Wichtig zu erwähnen hierbei ist, dass diese Zahlen nicht die Gesamtheit aller EoL-Mengen darstellen, da ein erheblicher Teil durch unkontrollierte Exporte in das Ausland gerät. Derzeit existieren noch keine exakten Abschätzungen über den Anteil der Exportmengen von Second Life Modulen

<sup>11</sup> Widodo and Yang, “Application of Relevance Vector Machine and Survival Probability to Machine Degradation Assessment”; Ragab et al., “Remaining Useful Life Prediction Using Prognostic Methodology Based on Logical Analysis of Data and Kaplan–Meier Estimation.”

<sup>12</sup> Goel, Khanna, and Kishore, “Understanding Survival Analysis.”

<sup>13</sup> Prinja, Gupta, and Verma, “Censoring in Clinical Trials.”

in das hauptsächlich nicht-europäische Ausland. Weiterhin problematisch ist, dass über den Zoll diese Mengen nicht unter einer eigenen Exportnummer getrackt werden. Erste Studien vermuten jedoch einen Exportanteil zwischen 30 und 70% in Länder wie Frankreich, Deutschland und Italien <sup>14</sup>.

### Logistische Regression

In der letzten Phase der Datenanalyse wurde ein logistisches Regressionsmodell (LR) verwendet, um die Altanlagen im Datensatz zu klassifizieren. LR ist ein weit verbreitetes Klassifizierungsmodell, das besonders effektiv für binäre und lineare Klassifizierungsprobleme mit linear trennbaren Klassen ist <sup>15</sup>. LR wurde in dieser Studie aufgrund seiner Interpretierbarkeit, seiner Recheneffizienz und seiner Fähigkeit, wahrscheinkeitsbasierte Vorhersagen zu liefern, bevorzugt, die es uns ermöglichen, die Wahrscheinlichkeit des Auftretens von EoL bei einer PV-Anlage zu bewerten. Alternative Modelle wie Entscheidungsbäume oder Support Vector Machines könnten zwar auch eine binäre Klassifizierung vornehmen, sind aber oft weniger gut interpretierbar oder erfordern mehr Rechenressourcen <sup>16</sup>. In Anbetracht des Ziels, die Schlüsselmerkmale zu verstehen, die EoL beeinflussen, wurde LR als die geeignetste Wahl für die Klassifizierung angesehen, ob eine PV-Anlage am Ende ihres Lebenszyklus („1“) oder noch aktiv („0“) ist. Die Wahrscheinlichkeit, dass für die gegebenen Werte der unabhängigen Variablen die abhängige Variable  $y$ , d. h., ob sich die PV-Anlage am Ende der Lebensdauer befindet, „1“ oder „0“ ist, ist gegeben durch:

$$p(y = 1) = \frac{1}{1 + e^{-(b_1 * x_1 + \dots + b_k * x_k + a)}} \text{ and } p(y = 0) = 1 - \frac{1}{1 + e^{-(b_1 * x_1 + \dots + b_k * x_k + a)}}$$

wobei  $x_{1-k}$  unabhängige Variablen darstellen, die den Merkmalen entsprechen, die jeder PV-Anlage zugeordnet sind. Darüber hinaus quantifizieren die Regressionskoeffizienten  $b_{1-k}$  die Auswirkung jedes Prädiktors auf die Wahrscheinlichkeit, dass die abhängige Variable „1“ ist, und zeigen den Einfluss jedes Merkmals auf die EoL-Klassifizierung an.

## 3. Ergebnisse

Nachfolgend werden die im AP3 gewonnenen Ergebnisse vorgestellt und anschliessend diskutiert. Da sowohl 0, als auch 1 im Rahmen einer wissenschaftlichen Studie aufbereitet wurden, werden die Ergebnisse in diesem Bericht lediglich aggregiert und ohne Abbildungen zusammengefasst.

### 3.1 Merkmalsausprägungen von EoL-Anlagen

Um verbesserte Aussagen über die Merkmalsausprägungen abgebauter PV-Anlagen treffen zu können, wurden diese mittels qualitativ-explorativem Ansatz untersucht. Grundlage für diese Untersuchung waren etwa 530 Anlagen, welche durch den Datenvorbereitungsprozess und das Zusammenführen verschiedener Quellen als eindeutige EoL-Anlagen identifiziert wurden und zudem alle benötigten Informationen aufwiesen. Die Grundlage für die Zuordnung des EoL-Grunds lieferten die Abholaufträge von SENS eRecycling, in denen ein Abholgrund (bspw. 'Ende der Nutzung', 'Materialfehler', oder 'Sonstiges') hinterlegt war. Besonders häufig wurden Anlagen in den vergangenen Jahren mit dem Grund 'Hagelschaden' oder 'Sturmschaden' versehen. Um die Angaben zu ergänzen und verifizieren, wurde für die Zuordnung des EoL-Grunds das Alter der

<sup>14</sup> Hansen et al., "The Dark Side of the Sun: Solar e-Waste and Environmental Upgrading In."

<sup>15</sup> Subasi, *Practical Machine Learning for Data Analysis Using Python*.

<sup>16</sup> Stoltzfus, "Logistic Regression."

Anlage, sowie das Satellitenfoto überprüft, um nachzuweisen, ob ein Wechsel (bspw. Repowering) oder ein endgültiger Abbau (bspw. Ende der Nutzung) stattgefunden hat. Durch die Überprüfung der Satellitenhistorie fiel ebenfalls auf, dass ein grösserer Anteil der Anlagen durch Bauarbeiten abgebaut wurde. Wie unter 2.1 bereits erwähnt wurde, konnte über das SPF Institut für Solartechnik der OST-Hochschule ein Datensatz zu Hagelschäden aus dem Jahr 2021 für die Analyse verwendet werden. Da jedoch dieser Datensatz das Bild über eine mögliche Verteilung der EoL-Gründe verfälschen könnte, ist unter Abbildung die Darstellung der EoL-Gründe ohne die SPF-Hageldata aufgeführt. Die Abbildung zeigt, dass nur ein Sechstel aller Anlagen mit dem Grund 'Ende der Nutzung' versehen wurde. Ein weitaus grösserer Anteil der EoL-Anlagen ist durch unvorhergesehene Ereignisse, beispielsweise Schäden, Materialfehler oder Hagel, in den Abfallstrom gelangt. Interessant hierbei ist auch zu erwähnen, dass der grösste Anteil identifizierter EoL-Anlagen ein Repowering erhalten hat. Jedoch kann man hier nicht sicher sagen, ob dieses Repowering durch einen Materialfehler oder aus rein ökonomischen Zwecken veranlasst wurde.




Abbildung 1: Identifizierte EoL-Gründe bei abgebauten Anlagen.

Weiterhin wurde das Installationsjahr abgebauter Anlagen untersucht, wobei sich zeigte, dass die meisten Anlagen nach 2009 und ein erheblicher Teil erst ab 2015 installiert wurde. Der Grund für diese Beobachtung könnte zum einen der steigende Anstieg von PV-Anlagen sein, der im selben Zug einen steigenden Anstieg an EoL-Anlagen mit sich bringt. Weiterhin könnten die zunehmenden Extremwetterereignisse eine steigende Auswirkung auf die stärker bebaute PV-Fläche haben. Investitionsentscheidungen für Anlagen, die in den letzten 7 – 10 Jahren installiert wurden, könnten ebenfalls zu einem vorzeitigen Repowering führen <sup>17</sup>.

<sup>17</sup> Sodhi et al., "Economic Lifetimes of Solar Panels."




Abbildung 2: Installationsjahre von EoL-Anlagen.

Ein weiterer für die Untersuchung der Merkmalsausprägungen interessanter Parameter ist die installierte Kapazität der Anlagen. Während EoL-Installationen eine Kapazität von etwa 114kWp aufwiesen, liegt die durchschnittliche Kapazität bei allen aktiven Anlagen bei durchschnittlich 24kWp. Zudem haben etwa 89% aller aktiven Anlagen eine Kapazität von unter 30kWp, während es bei den EoL-Anlagen nur etwa 48% sind. Einige Gründe können Einfluss auf diese unterschiedlichen Zahlen haben. Zum einen kann es sein, dass Besitzer:innen von Kleinanlagen diese tendenziell eher zu Sammelstellen bringen (wo sie schliesslich im Datensatz nicht mehr nachverfolgbar sind) als eine Abholung zu beauftragen. Weiterhin könnte es sein, dass Privatbesitzer:innen ihre Anlagen häufiger für den direkten Wiederverkauf (bspw. als Occasionmodule) an Zwischenhändler abgeben oder über Online-Marktplätze verkaufen. Dennoch lässt sich ebenfalls vermuten, dass finanzielle Anreize zum vorzeitigen Wechsel der Anlagen, etwa durch Repowering, eher für grössere Anlagen im industriellen Massstab relevant sind. Dies könnte ebenfalls einen Einfluss auf die grosse Kapazität der EoL-Anlagen haben.




Abbildung 3: Verteilung der installierten Kapazität (kWp) nach Kategorien bei EoL-Anlagen.




Abbildung 4: Verteilung der installierten Kapazität (kWp) nach Kategorien aller derzeit installierten PV-Anlagen.

Weitere Untersuchungen, wie etwa die geografische Zuordnung von EoL-Anlagen, wurden ebenfalls im Rahmen des AP3 durchgeführt. Insgesamt zeigte sich mit dieser Analyse, dass abgebaute Anlagen kennzeichnende Merkmale aufweisen, um sie von noch aktiven Anlagen trennen zu können. Nebst dem Satellitenfoto können die Energieproduktionsdaten, beispielsweise bei Änderungen der erzeugten Erträge, einen wichtigen Indikator für die Identifikation weiterer EoL-Anlagen darstellen. Ebenfalls wurde festgestellt, dass Anlagen mit bestätigtem EoL häufiger eine Erweiterung erhalten haben als aktive Anlagen, was auf einen Wechsel und darauffolgend einem Leistungszubau bei neuen Modulen hindeuten kann. Diese

Informationen sind wichtige Grundvoraussetzungen, um herauszufinden, ob eine algorithmische Klassifizierung von EoL-Anlagen mittels ML-Modell möglich ist.

### 3.2 Alter von EoL-PV-Anlagen

Da das Alter der PV-Anlage ein entscheidender Faktor zur Beurteilung der Reuse-Fähigkeit ist, wurde eine Kaplan-Meier-Analyse angewendet, welche die Lebensdauer von identifizierten EoL Anlagen untersuchte. Die Analyse ergab, dass die mediane Überlebenszeit der untersuchten EoL-Module etwa sieben Jahre (interpolierter Wert) beträgt. Diese Ergebnisse stehen im Einklang mit früheren Studien, die wirtschaftlich motivierte frühe Ersatzentscheidungen (Repowering) sowie frühe Ausfallereignisse (Wetterereignisse, Designfehler etc.) als zentrale Faktoren für ein vorzeitiges EoL identifizieren<sup>18</sup>. Interessanterweise zeigte sich, dass nur ein kleiner Teil (~4 %) der abgebauten Systeme älter als 15 Jahre war, während ein erheblicher Anteil (20%) bereits innerhalb des ersten Lebensjahres in den EoL-Strom gelangte.

Ein besonderer Faktor für frühe Ausfälle war Hagelschaden, der unabhängig vom Alter der Module auftrat. Da durch den Klimawandel zunehmend extreme Wetterereignisse erwartet werden, könnte dies zukünftig eine grössere Rolle spielen. Weiterhin wurde die mediane Lebenszeit von sieben Jahren bereits in vergangenen Studien (bspw.<sup>19</sup>) als ökonomische Lebenszeit der Anlage diskutiert, was durch den hohen Anteil von Repowering-Anlagen (siehe 3.1) bestätigt werden konnte. Die Kaplan-Meier-Kurve zeigte bei Untersuchung aller bisher installierten Anlagen (inkl. EoL), dass PV-Systeme nach 30 Jahren noch eine Überlebenswahrscheinlichkeit von etwa 94% aufwiesen, was für die allgemeine Langlebigkeit der Produkte spricht. Diese Ergebnisse verdeutlichen die Notwendigkeit, regulative Massnahmen zur Förderung einer nachhaltigen Nutzung von PV-Modulen zu ergreifen und die Wiederverwendung intakter Module zu fördern.

### 3.3 Forecasting der EoL-Mengen bis 2050

#### 3.3.1 Forecasting mittels SENS-Abholmengen

Für die Erstellung eines Forecasts wurden als erstes potenzielle zukünftige EoL-Mengen unter Berücksichtigung der SENS-Abholmengen berechnet (siehe 2.3.1). Diese Berechnung prognostiziert einen Anstieg des EoL-Volumens auf ca. 22'000t bis zum Jahr 2050. Die berechneten Werte für die Jahre 2024 – 2050 sind in Tabelle 1 im Anhang angefügt. Diese initiale Abschätzung soll einen möglichen ersten Schritt zur Darstellung der EoL-Mengen aufzeigen, jedoch gilt hier zu betonen, dass die Abholmengen von SENS nicht die absolute Gesamtmenge der EoL-Anlagen darstellt, da wie eingangs erklärt, ein erheblicher Anteil in den Export fliesst<sup>20</sup>. Unter Berücksichtigung der aktuellen Exportdaten für PV des Bundesamts für Statistik kann somit davon ausgegangen werden, dass mindestens 30% (siehe Deliverable 5.2) der aktuell rapportierten Abholdaten in den Export abfliessen könnten<sup>21</sup>, d.h. im Jahr 2023 etwa 200t. Zudem können direkte kommerzielle Wiederverkäufe von Second-Life-Modulen innerhalb der Schweiz (bspw. als Occasionsmodule) die Dunkelziffer weiter beeinflussen. Offizielle Zahlen hierzu gibt es bisher keine.

---

<sup>18</sup> Gupta et al., "Impact of Hailstorm on the Performance of PV Module: A Review"; Sodhi et al., "Economic Lifetimes of Solar Panels."

<sup>19</sup> Sodhi et al., "Economic Lifetimes of Solar Panels."

<sup>20</sup> Hansen et al., "The Dark Side of the Sun: Solar e-Waste and Environmental Upgrading In."

<sup>21</sup> BAZG, "Bundesamt für Zoll und Grenzsicherheit."

Es zeigt sich, dass verschiedene Faktoren einen Einfluss auf die Berechnung von EoL-Mengen in den kommenden Jahren beeinflussen können, jedoch ermöglicht die aktuelle Datengrundlage nur wenige Einblicke in potenzielle Abweichungen von den gemeldeten Abholmengen. Um weitere Einblicke zu ermöglichen, ist eine verbesserte Übersicht der effektiven Anzahl der bisherigen EoL-Anlagen notwendig, weshalb nachfolgend ein aufwendigerer Ansatz zur Identifikation bisheriger EoL-Anlagen entwickelt wurde.




Abbildung 5: Erste Einschätzung zukünftiger EoL-Mengen bis 2050, Basis Regressionsmodell. Die für das Jahr 2024 abgebildete Abholmenge wurde ebenfalls durch das Modell berechnet, da zum Zeitpunkt der Messung noch keine offiziellen Zahlen für 2024 vorlagen.

### 3.3.2 Forecasting mittels EoL-Classification

#### Training und Testing ML-Modell

Um ein Forecast basierend auf der absoluten Menge identifizierter EoL-Anlagen zu ermöglichen, musste in mehreren Schritten vorgegangen werden. Zunächst wurde zur Untersuchung der Klassifizierung von EoL-Anlagen ein logistisches Regressionsmodell mit etwa 1'200 Datenpunkten trainiert und etwa 300 Datenpunkte getestet (Gewichtung 80% zu 20%). Für die Anwendung des Modells wurde ein Datensatz zusammengestellt, der den grösstmöglichen Umfang an Informationen (bspw. Alter, Ort, Kapazität, Ertrag) für jede Anlage bereitstellt. Die Ergebnisse der logistischen Regression zeigen, dass dieses Modell mit hoher Genauigkeit in der Lage ist, EoL PV-Systeme zu klassifizieren. Die Gesamtgenauigkeit des Modells betrug 89,3%, während eine 10-fache Kreuzvalidierung eine durchschnittliche Genauigkeit von 85,4% mit einer Standardabweichung von 2,59% ergab. Diese Ergebnisse deuten auf eine robuste Modellleistung hin, selbst bei unterschiedlichen Datensätzen.

Ein Blick auf die Confusion Matrix zeigt, dass das Modell eine höhere Spezifität (93,7%) als Sensitivität (86,3%) aufweist. Das bedeutet, dass das Modell besser darin ist, aktive Systeme korrekt als „nicht EoL“ zu erkennen, während es etwas weniger genau Systeme korrekt als EoL identifiziert.

Die wichtigsten Einflussfaktoren für das EoL-Risiko wurden mittels der berechneten Chancenverhältnisse ermittelt. Dabei zeigte sich, dass geografische Variablen, wie der Kanton Luzern (LU), eine besonders hohe

Bedeutung haben – hier war das Risiko eines EoL-Vorkommens 21-mal höher als in anderen Regionen. Weitere wichtige Einflussfaktoren waren das Alter des Systems, die Anzahl der Unterbrechungsmonate sowie das Förderprogramm „KEV“ für ältere Systeme. Das Modell deutet zudem darauf hin, dass Systeme mit bestimmten Ertragsprofilen (z. B. Yield\_2019 und Yield\_2016) anfälliger für ein frühes EoL sind.

### EoL-Klassifizierung

In einem zweiten Schritt wurde das vortrainierte Modell eingesetzt, um weitere potenzielle EoL-Anlagen im vollständigen Datensatz (n= 157'000) zu identifizieren. Hierfür wurde zunächst ein Subset des EoL-Datensatzes (n=100) erstellt, um Verzerrungen im Sample (z.B.: durch kantons- oder jahresspezifische Hagelschäden) zu reduzieren. Zudem wurde ein ausgewogenes Verhältnis zwischen EoL-Anlagen (10%) und aktiven Anlagen (90%) angestrebt, da davon auszugehen ist, dass der Gesamtanteil deinstallierter Anlagen vergleichsweise gering ist<sup>22</sup>. Interessanterweise zeigte das Modell trotz angepasstem Datensatz weiterhin, dass die kantonalen Variablen für Luzern und Zug noch immer den grössten Einfluss auf die EoL-Klassifizierung darstellen, was nebst dem erhöhten Hagelaufkommen, auch mit der höheren PV-Anlagendichte (10 Anlagen/km<sup>2</sup>; zum Vergleich in Bern sind es 6 Anlagen/km<sup>2</sup>) zusammenhängen könnte<sup>23</sup>. Weiterhin stieg die Genauigkeit des Modells mit angepasstem Sample auf eine Genauigkeit von 93.7%.

Zur Klassifizierung neuer EoL-Anlagen berechnete das Modell für jeden Datenpunkt die Eintrittswahrscheinlichkeit eines EoL-Ereignisses. Datenpunkte mit einer Wahrscheinlichkeit über 0,5 wurden als «EoL» klassifiziert, was zu einer Gesamtanzahl von 3'183 klassifizierten Anlagen führte (siehe Abbildung 6). Unter Verwendung eines Umrechnungskoeffizienten von 100kg/kWp ergibt sich daraus eine Gesamtmenge von 23'061t, die bis 2023 als EoL klassifiziert wurden – entsprechend 2% aller untersuchten Anlagen.

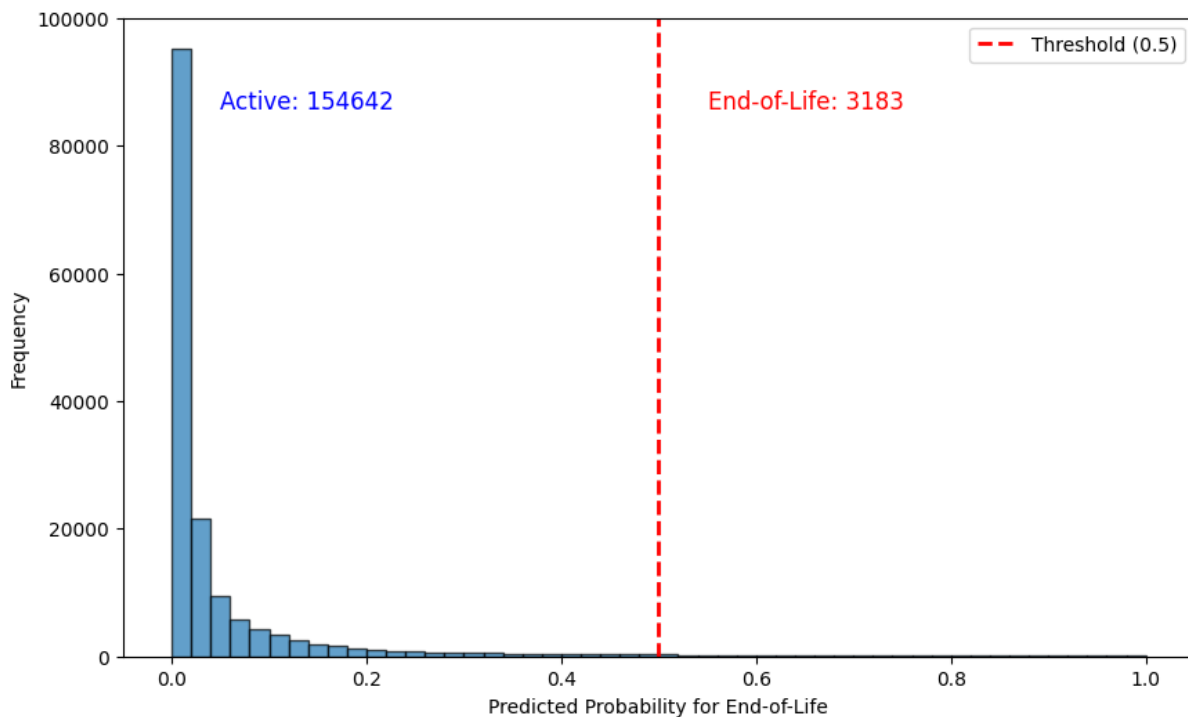


Abbildung 1: Verteilung klassifizierter End-of-Life Anlagen.

<sup>22</sup> Rabaia, Semeraro, and Olabi, "Recent Progress towards Photovoltaics' Circular Economy".

<sup>23</sup> Opendata.Swiss, "Electricity Production Plants - Opendata.Swiss."

In einem dritten Schritt dienen die klassifizierte EoL-Mengen als Grundlage für eine Forecast-Berechnung, bei der der Anstieg der Kurve auf Basis der SENS-Abholmengen von 2015 bis 2023 modelliert wurde. Für den Forecast wurde wieder eine polynomiale Regression verwendet, welche einen Anstieg der EoL-Mengen auf etwa 90'000 t bis 2050 prognostiziert (siehe Abbildung 7).

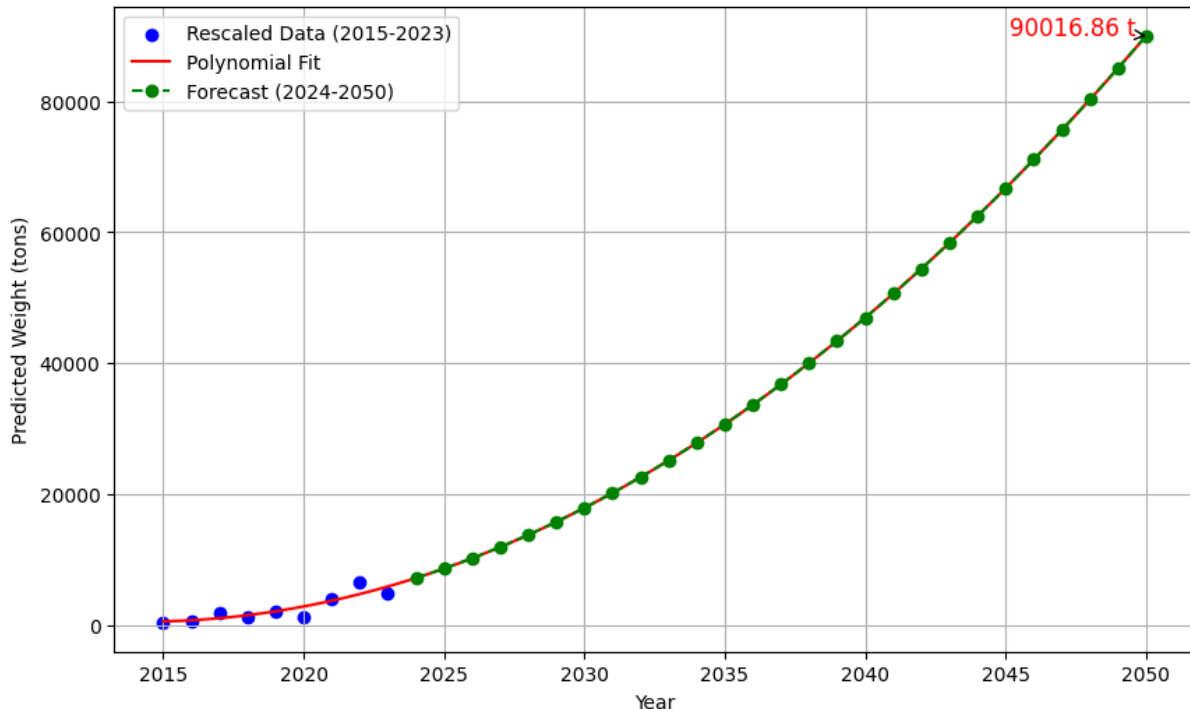


Abbildung 2: Upgedatetes Forecast bis 2050 unter Berücksichtigung ML-klassifizierter EoL-Mengen bis 2023.

### 3.3.3 Vergleich mit bestehenden Studien

Um einen Vergleich dieser ersten Berechnung für die Schweiz mit bestehenden Studien zu ermöglichen, wurden exemplarisch zwei Studien untersucht, welche verschiedene Verfahren für die Berechnung von EoL-Mengen angewendet haben.

#### Forecast Studie IRENA und Wambach Consulting (2022)

Grundlage des Forecasts bildet der Bericht «End-of-Life-Management Solar Photovoltaic Panels» der International Energy Agency (IEA) zusammen mit der International Renewable Energy Agency (IRENA) aus dem Jahr 2016<sup>24</sup> <sup>25</sup>. Hierbei erfolgt die Anwendung der Weibull-Verteilung als methodische Grundlage für die Berechnung der EoL Mengen unter Annahme einer durchschnittlichen PV-Anlagenlebensdauer von etwa 30 Jahren und einer Verlustwahrscheinlichkeit von 99.9% nach spätestens 40 Jahren. Die Berechnung der Weibull-Kurve erfolgt unter:

$$F(t) = 1 - e^{-\left(\frac{t}{T}\right)^\alpha}, \text{ wobei}$$

t = Zeit in Jahren

T = Durchschnittliche Lebenszeit

<sup>24</sup> Weckend, Wade, and Heath, "End of Life Management."

<sup>25</sup> "Swissolar," 2025.

$\alpha$  = Formfaktor, verantwortlich für S-Form der Weibull-Kurve




Abbildung 8: Forecast nach Irena und Wambach Consulting (2022).

Für die Berechnung der Shape-Parameter für die Weibull-Kurve wurden in weiteren Studien Sammlungsdaten aus verschiedenen Ländern, etwa Frankreich, Italien, Belgien und den Niederlanden verwendet<sup>26</sup>. Allerdings ist hierbei zu erwähnen, dass diese Studien vor knapp 10 Jahren durchgeführt wurden und demnach auch die daran berücksichtigten Grundannahmen und Basisdaten aus dieser Zeit entstanden sind. Weiterhin wurden die Zahlen aus dem gesamteuropäischen Kontext auf die Schweiz für die Berechnung abgeleitet, wodurch sich eine Gesamtmenge von ca. 530'000t bis 2050 ergab. Sicher ist nicht, ob es sich hierbei um einen kumulierten Wert handelt, was jedoch unter Betrachtung der in den vergangenen Jahren installierten PV-Mengen plausibel wäre. Zudem wurde von einer höheren Ausgangsmenge (> 2'000t) im Jahr 2023 ausgegangen. Diese und weitere Faktoren können die deutlich (20-fach) höhere Menge an berechneten EoL-Volumen bis 2050 erheblich beeinflussen.

#### Forecast Czajkowski et al. (2022)

Die zweite Studie entwickelte einen Einsatz, der einerseits die Berücksichtigung der Massenindikatoren und Anteile verschiedener PV-Technologien (c-Si, a-Si, CdTe und CIGS) erlaubt. Weiterhin bildet die retrospektive Betrachtung der installierten PV-Mengen aus den vergangenen Jahren seit 1996 die Grundlage für die Projektion der zukünftigen PV-Abfallmengen, hierbei jedoch unter Berücksichtigung einer durchschnittlichen Lebensdauer von 25 Jahren<sup>27</sup>. Da die Studie die Schweiz nicht als Use Case untersuchte, wurde die Methodik im Rahmen vom AP3 unter Berücksichtigung der installierten Kapazitäten (Grundlage

<sup>26</sup> Forti, Baldé, and Kuehr, "E-Waste Statistics"; Magalani et al., "Study on Collection Rates of Waste Electrical and Electronic Equipment."

<sup>27</sup> Czajkowski et al., "Prediction of the Market of End-of-Life Photovoltaic Panels in the Context of Common EU Management System."

Pronovo und Swissolar) von 1996–2023 abgeleitet und mit den Installationszahlen von Swissolar angewendet<sup>28</sup>. Die Berechnung erfolgt unter:

$$M_y = (C_x - C_{x-1}) * u_{x,t} * w_t, \text{ wobei}$$

$C$  = die in einem bestimmten EU-Land installierte Photovoltaikkapazität in MW;

$t$  = ein Typ der Photovoltaik-Technologie;

$y$  = ein Jahr der EoL-Photovoltaik-Abfallerzeugung;

$x$  = das Jahr der Installation von Photovoltaikanlagen;

$u$  = der Anteil einer bestimmten PV-Technologie im Jahr  $x$ ;

$w$  = ein Massenindikator für PV-Paneele verschiedener Photovoltaiktechnologien, kg/W.

Hierbei ergab sich eine Rücklaufmenge von etwa 147'000t bis 2050. Potenzielle Exportmengen oder direkte Reuse-Verkäufe wurden in diesem Vorgehen ebenfalls nicht berücksichtigt.




Abbildung 9: Forecast auf Basis Czajkowski et al. (2022).

Die drei vorgestellten Methoden zeigen, dass viele Einflussfaktoren für die Berechnung von EoL-Mengen, aber teilweise ungenügende Daten zur Verfügung stehen. Grundsätzlich ist davon auszugehen, dass eine Menge von 533'000t bis 2050 sehr hoch ist, wenn man berücksichtigt, dass im Jahr 2024 erst ca. 40'000t (unter Berücksichtigung einer gesamten Installationskapazität von 489'862kWp und geschätzt 20 kg/Modul à 250Wp) installiert wurden. Deshalb kann davon ausgegangen werden, dass sich ein realistischer Wert zwischen etwa 20'000 und 100'000t bewegt, wobei verschiedene Faktoren, wie ein stark fluktuierendes Modulgewicht und steigende Effizienzen diesen Wert erheblich beeinflussen können. Hinzu kommen erhebliche Exportmengen, die tendenziell in den kommenden Jahren weiter ansteigen können<sup>29</sup>. Da jedoch keine der vorgestellten Ansätze eine möglichst reale Projektion erlaubt, ist eine Identifikation der effektiven EoL-Mengen von wichtiger Bedeutung. Aus diesem Grund wurde weiterhin ein Machine Learning Ansatz angewendet, welcher eine wahrscheinlichkeitsbasierte Klassifizierung von EoL-Anlagen im erstellten

<sup>28</sup> "Swissolar," 2025.

<sup>29</sup> Hansen et al., "The Dark Side of the Sun: Solar e-Waste and Environmental Upgrading In."

Datensatz ermöglicht. Dieses ML-Modell bietet die Grundlage für die Identifikation weiterer EoL-Anlagen, um eine verbesserte Abschätzung über EoL-Volumen treffen zu können. Hierfür ist entscheidend, die Merkmalsausprägungen abgebauter Anlagen zu verstehen und daraus Muster für das Modell abzuleiten. Hierfür wurde zunächst eine qualitative Analyse durchgeführt.

## 4. Diskussion der Ergebnisse

Die aufgeführten Ergebnisse verdeutlichen, dass ein Forecasting von EoL-Anlagen von vielen Faktoren abhängt, darunter eine umfangreiche und qualitativ hochwertige, historische Datengrundlage. Mittels hohen Aufwands konnte ein guter Grundbestand an EoL-Anlagen entwickelt werden, um erste Aussagen zu den Merkmalsausprägungen dieser Anlagen treffen zu können. Vor allem durch die Kaplan-Meier Analyse konnte gezeigt werden, dass aktuelle EoL-Module meist nicht das Ende ihrer technischen Lebenszeit erreicht haben, sondern als Frühausfälle eingestuft werden können. Dies trifft vor allem bei Anlagen zu, welche bereits in den ersten zwei Jahren der Installationszeit in den Abfallstrom gelangen. Materialfehler, Produktionsfehler, und vorhergesehene Schäden können diese verkürzte Lebenszeit beeinflussen<sup>30</sup>. Weiterhin konnten unsere Ergebnisse zeigen, dass vor allem Hagel einen zunehmenden Einfluss auf PV-Schäden haben wird, zum einen, weil extreme Wetterereignisse tendenziell zunehmen werden, und zum anderen, weil immer mehr Fläche mit PV-Anlagen verbaut wird<sup>31</sup>. Ökonomische Faktoren können den vorzeitigen Wechsel von PV-Modulen (Repowering) nach den ersten 7 - 10 Jahren motivieren, was sich mit Ergebnissen bestehender Studien zur ökonomischen Lebenszeit deckt<sup>32</sup>. Dies verdeutlicht die Relevanz politischer Anreize zur Förderung einer möglichst langen Produktlebenszeit.

Weiterhin wurde eine exemplarische Projektion zukünftiger EoL-Volumen auf Basis vergangener Abholmengen durchgeführt und mit bestehenden Studien gegenübergestellt<sup>33</sup>. In einem weiteren Schritt wurden weitere EoL-Anlagen im Datensatz klassifiziert und mittels Regressionsmodell auf die Zukunft projiziert.

Grundsätzlich lässt sich sagen, dass ein Forecast aufgrund der aktuellen Datenlage und der Aktualität und Qualität dieser Daten eingeschränkt ist. Die Ergebnisse zeigen leichte bis starke Abweichungen von bestehenden Studien, wovon die Weibull-Methode<sup>34</sup> und ein selbst entwickelter Ansatz auf Basis installierter PV-Mengen<sup>35</sup> untersucht wurden. Jedoch beziehen sich diese Studien auf mehrere Annahmen, beispielsweise einer durchschnittlichen Lebenszeit von 25 oder 30 Jahren, und historischen Daten aus verschiedenen Ländern, welche aktualisiert werden sollten und die Schweiz in diese Überlegungen nicht mit einbeziehen. Aus diesem Grund ist ein wichtiger Schritt für ein verbessertes Forecasting eine umfangreiche Identifikation von EoL-Anlagen, basierend auf kennzeichnenden Merkmalsausprägungen zu etablieren. Das

---

<sup>30</sup> Aghaei et al., "Review of Degradation and Failure Phenomena in Photovoltaic Modules."

<sup>31</sup> Rabaia, Semeraro, and Olabi, "Recent Progress towards Photovoltaics' Circular Economy"; Gupta et al., "Impact of Hailstorm on the Performance of PV Module: A Review."

<sup>32</sup> Sodhi et al., "Economic Lifetimes of Solar Panels."

<sup>33</sup> Forti, Baldé, and Kuehr, "E-Waste Statistics"; Magalani et al., "Study on Collection Rates of Waste Electrical and Electronic Equipment"; Weckend, Wade, and Heath, "End of Life Management"; Czajkowski et al., "Prediction of the Market of End-of-Life Photovoltaic Panels in the Context of Common EU Management System."

<sup>34</sup> Forti, Baldé, and Kuehr, "E-Waste Statistics"; Magalani et al., "Study on Collection Rates of Waste Electrical and Electronic Equipment"; Weckend, Wade, and Heath, "End of Life Management."

<sup>35</sup> Czajkowski et al., "Prediction of the Market of End-of-Life Photovoltaic Panels in the Context of Common EU Management System."

hierfür entwickelte Logistische Regressionsmodell bietet einen geeigneten Startpunkt, um zukünftig weitere EoL-Instanzen im Datensatz einzupflegen und die Genauigkeit des Modells zu optimieren.

Mit dieser ersten Datengrundlage können zukünftig Entscheidungshilfen entwickelt werden, welche Unternehmen mit Engagement in der Kreislaufwirtschaft dabei unterstützen sollen, frühzeitige Reuse-Entscheidungen zu treffen. Ein erster Ansatz wurde innerhalb des AP3 bereits gemeinsam mit SENS eRecycling entwickelt, wobei zukünftige Abholaufträge eine Vorsortierung integrieren könnten, die eine Triage zwischen Wiederverwendung und Recycling ermöglichen. Faktoren, welche in Zusammenarbeit mit den anderen Arbeitspaketen als relevant für die Reuse-Entscheidung erarbeitet wurden, stellen relevante Verzweigungen dar. So eignen sich beispielsweise grössere PV-Anlagen, (beispielsweise mit einer Installationskapazität über 30 kWp) mehr für eine Wiederverwendung, da die zu testende Module eine ähnliche Historie und somit Residualleistung und Qualität aufweisen. Ebenfalls relevant für die Entscheidung ist der Zustand der PV-Module. Während optisch intakte Module potenziell für ein zweites Leben geeignet sind, sollten intakte Module direkt in den Abfallstrom gelangen, um unnötige Test-Kosten zu minimieren.

Doch auch für politische Entscheidungsträger:innen bieten diese Erkenntnisse wichtige Anstösse für die zukünftige Entwicklung von Gesetzgebungen und Standards. Zum einen zeigt unsere Untersuchung, dass ein verbessertes Datenmanagement ein wichtiger Treiber der Kreislaufwirtschaft ist, da verbesserte Informationen zu EoL Produkten ein relevanter Faktor für die Kosteneffizienz von kreislauffähigen Geschäftsmodellen ist. Weiterhin zeigt sich, dass regulatorische Anreize für die möglichst nachhaltige (verlängerte) Nutzung von PV-Anlagen relevant sind, um vorzeitigem Wechsel entgegenzuwirken. Weiterhin bedarf es einer intensivierten Aufklärung von Akteur:innen in der Solarbranche, um Wiederverwendungsaktivitäten frühzeitig in der Wertschöpfung, am besten vor dem Abbau, zu fördern.

## 5. Ausblick und Fazit

Die ersten Ergebnisse, welche im Rahmen des 'Swiss PV Circle' Projekts entwickelt wurden, bieten den Startpunkt für weitere Analysen. Zukünftig soll demnach das Forecasting mit neuen EoL-Anlagen erweitert werden, um eine effizientere Abschätzung der EoL-Volumen, basierend auf genaueren Zahlen zu heutigen Rückläufen, zu ermöglichen. Darüber hinaus sollten systemische Anpassungen zukünftig das Datenmanagement hinsichtlich Kreislaufwirtschaft verbessern. Ein ausführlicher Empfehlungsrahmen wurde hierfür im Rahmen von AP1 entwickelt. Die aktuellen Ergebnisse basieren derzeit noch auf einem kleinen Bestand von EoL-Anlagen, welche innerhalb des Projekts entwickelt werden konnten. Mit weiteren Bestrebungen, gestützt durch Datenanalyse-Techniken, soll dieser Bestand erweitert werden, um genauere Aussagen zu ermöglichen.

## Anhang

### Anhang 1: Finale berechnete Werte für jährliche PV-End-of-Life-Mengen 2024 – 2050, Basis logistische Regression.

<b>Nr.</b>	<b>Jahr</b>	<b>Tonnen total</b>
0	2024	7178.42
1	2025	8614.86
2	2026	10191.28
3	2027	11907.67
4	2028	13764.03
5	2029	15760.37
6	2030	17896.67
7	2031	20172.95
8	2032	22589.20
9	2033	25145.42
10	2034	27841.61
11	2035	30677.78
12	2036	33653.91
13	2037	36770.02
14	2038	40026.10
15	2039	43422.15
16	2040	46958.18
17	2041	50634.17
18	2042	54450.14
19	2043	58406.08
20	2044	62501.99
21	2045	66737.87
22	2046	71113.73
23	2047	75629.55
24	2048	80285.35
25	2049	85081.12
26	2050	90016.86

## Literatur

- Aghaei, M., A. Fairbrother, A. Gok, S. Ahmad, S. Kazim, K. Lobato, G. Oreski, et al. "Review of Degradation and Failure Phenomena in Photovoltaic Modules." *Renewable and Sustainable Energy Reviews* 159 (May 1, 2022): 112160. <https://doi.org/10.1016/j.rser.2022.112160>.
- Altman, Douglas G. *Practical Statistics for Medical Research*. New York: Chapman and Hall/CRC, 1990. <https://doi.org/10.1201/9780429258589>.
- BAZG, Bundesamt für Zoll und Grenzsicherheit. "Bundesamt für Zoll und Grenzsicherheit." Accessed January 9, 2025. <https://www.bazg.admin.ch/bazg/de/home.html>.
- Czajkowski, Adrian, Agata Wajda, Nikolina Poranek, Shubhangi Bhadoria, and Leszek Remiorz. "Prediction of the Market of End-of-Life Photovoltaic Panels in the Context of Common EU Management System." *Energies* 16, no. 1 (January 2023): 284. <https://doi.org/10.3390/en16010284>.
- Forti, Vanessa, Kees Baldé, and Ruediger Kuehr. "E-Waste Statistics," 2018. [https://collections.unu.edu/eserv/UNU:6477/RZ\\_EWaste\\_Guidelines\\_LoRes.pdf](https://collections.unu.edu/eserv/UNU:6477/RZ_EWaste_Guidelines_LoRes.pdf).
- Goel, ManishKumar, Pardeep Khanna, and Jugal Kishore. "Understanding Survival Analysis: Kaplan-Meier Estimate." *International Journal of Ayurveda Research* 1, no. 4 (2010): 274. <https://doi.org/10.4103/0974-7788.76794>.
- Goodwin, Paul, JKeith Ord, Lars-Erik Öller, Janet A. Sniezek, and Mike Leonard. "Principles of Forecasting: A Handbook for Researchers and Practitioners." *International Journal of Forecasting* 18, no. 3 (2002): 468–78. [https://doi.org/10.1016/S0169-2070\(02\)00034-1](https://doi.org/10.1016/S0169-2070(02)00034-1).
- Gupta, Vinay, Madhu Sharma, Rupendra Pachauri, and K N Dinesh Babu. "Impact of Hailstorm on the Performance of PV Module: A Review," March 31, 2022.
- Hansen et al. "The Dark Side of the Sun: Solar e-Waste and Environmental Upgrading In," 2022. <https://www.taylorfrancis.com/chapters/edit/10.4324/9781003259084-3/dark-side-sun-solar-waste-environmental-upgrading-grid-solar-pv-value-chain-ulrich-elmer-hansen-ivan-nygaard-mirko-dal-maso>.
- Hyndman, Rob J., and George Athanasopoulos. *Forecasting: Principles and Practice*. OTexts, 2018.
- Magalani, Federico, Feng Wang, Jaco Huisman, and Ruediger Kuehr. "Study on Collection Rates of Waste Electrical and Electronic Equipment," 2014. [https://ec.europa.eu/environment/pdf/waste/weee/Final\\_Report\\_Art7\\_publication.pdf](https://ec.europa.eu/environment/pdf/waste/weee/Final_Report_Art7_publication.pdf).
- Makridakis, Spyros, S. Wheelwright, and Rob Hyndman. "Forecasting: Methods and Applications." In *The Journal of the Operational Research Society*, Vol. 35, 1984. <https://doi.org/10.2307/2581936>.
- Opendata.Swiss. "Electricity Production Plants - Opendata.Swiss," 2024. <https://opendata.swiss/en/dataset/elektrizitatsproduktionsanlagen>.
- Patton, M. Q. "Enhancing the Quality and Credibility of Qualitative Analysis." *Health Services Research* 34, no. 5 Pt 2 (December 1999): 1189.
- Prinja, Shankar, Nidhi Gupta, and Ramesh Verma. "Censoring in Clinical Trials: Review of Survival Analysis Techniques." *Indian Journal of Community Medicine : Official Publication of Indian Association of Preventive & Social Medicine* 35, no. 2 (April 2010): 217–21. <https://doi.org/10.4103/0970-0218.66859>.
- Rabaia, Malek Kamal Hussien, Concetta Semeraro, and Abdul-Ghani Olabi. "Recent Progress towards Photovoltaics' Circular Economy." *Journal of Cleaner Production* 373 (November 1, 2022): 133864. <https://doi.org/10.1016/j.jclepro.2022.133864>.
- Ragab, Ahmed, Mohamed-Salah Ouali, Soumaya Yacout, and Hany Osman. "Remaining Useful Life Prediction Using Prognostic Methodology Based on Logical Analysis of Data and Kaplan–Meier Estimation." *Journal of Intelligent Manufacturing* 27, no. 5 (October 1, 2016): 943–58. <https://doi.org/10.1007/s10845-014-0926-3>.
- SENS eRecycling. "Recyclingsystem von Photovoltaik in der Schweiz." SENS eRecycling, 2024. <https://www.erecycling.ch/wissenswertes/wissensblog/fach-94.html>.
- Sodhi, Manbir, Lennart Banaszek, Chris Magee, and Mercedes Rivero-Hudec. "Economic Lifetimes of Solar Panels." *Procedia CIRP*, The 29th CIRP Conference on Life Cycle Engineering, April 4 – 6, 2022, Leuven, Belgium., 105 (January 1, 2022): 782–87. <https://doi.org/10.1016/j.procir.2022.02.130>.
- Stoltzfus, Jill C. "Logistic Regression: A Brief Primer." *Academic Emergency Medicine* 18, no. 10 (2011): 1099–1104. <https://doi.org/10.1111/j.1553-2712.2011.01185.x>.
- Subasi, Abdulhamit. *Practical Machine Learning for Data Analysis Using Python*. Academic Press, 2020.
- "Swissolar," 2025. <https://www.swissolar.ch/de/angebot/veranstaltungen/vortraege-und-studien>.
- "Swissolar," 2025. <https://www.swissolar.ch/de>.
- Thomas, David R. "A General Inductive Approach for Qualitative Data Analysis," 2003.
- Weckend, Stephanie, Andreas Wade, and Garvin A. Heath. "End of Life Management: Solar Photovoltaic Panels." Paris, France: International Energy Agency (IEA), June 1, 2016. <https://doi.org/10.2172/1561525>.
- Widodo, Achmad, and Bo-Suk Yang. "Application of Relevance Vector Machine and Survival Probability to Machine Degradation Assessment." *Expert Systems with Applications* 38, no. 3 (March 1, 2011): 2592–99. <https://doi.org/10.1016/j.eswa.2010.08.049>.