

# DomLearn

Domain-Informed Machine Learning for intelligent Energy Systems

<b>Programm / Ausschreibung</b>	Energieforschung (e!MISSION), Energieforschung, Energieforschung 7. Ausschreibung	<b>Status</b>	abgeschlossen
<b>Projektstart</b>	01.02.2022	<b>Projektende</b>	30.04.2023
<b>Zeitraum</b>	2022 - 2023	<b>Projektlaufzeit</b>	15 Monate
<b>Keywords</b>	Machine Learning; Deep Learning; künstliche Intelligenz; hybride Modellierung; Energy Services		

## Projektbeschreibung

Die Digitalisierung integrierter, regionaler Energiesysteme führt zur Entstehung von sogenannten cyber-physikalischen Energiesystemen, welche auf der Integration von softwaretechnischen Komponenten und physikalischen Prozessen basieren. In der Analyse und Optimierung dieser Systeme sind Methoden und Werkzeuge der Modellierung und Simulation von zentraler Bedeutung. Die steigenden Anforderungen an Modellierung und Simulation sind einer stetig wachsenden Menge an Betriebsdaten sowie dem Verschwinden der Sektorengrenzen zwischen Strom, Gas, Wärme, Kälte und Mobilität geschuldet. Dies hat zur Folge, dass etablierte Methoden der physikalischen und der datengetriebenen Modellierung und Simulation an ihre Grenzen stoßen. Die Entwicklung von domain-informierten, interpretierbaren und robusten Machine Learning Methoden und Algorithmen (kurz Domain-Informed Machine Learning) wird in der Forschungsgemeinschaft als radikale Innovation angesehen, welche diesen neuen Herausforderungen gerecht werden kann.

Argumente für das „Warum“ wurden kohärent und konsistent formuliert. Ziel des Sondierungsprojektes DomLearn ist es, erstmals das Potential für Domain-Informed Machine Learning im Bereich intelligenter Energiesysteme gemeinsam mit potentiellen AnwenderInnen aus der Industrie zu evaluieren. Des Weiteren werden gemeinsam mit internationalen ExpertInnen konkrete Implementierungen diskutiert. Anhand eines Proof of Concepts werden ausgewählte Lösung implementiert, getestet und evaluiert.

Die Projektergebnisse sollen dazu dienen, dass zukünftige Projekte auf eine objektive und rational nachvollziehbare Bewertung der Möglichkeiten und Einschränkungen von Domain-Informed Machine Learning aufbauen können. Somit dient das Projekt als Vorbereitung für zukünftigen Forschungs- und Entwicklungsvorhaben im Bereich intelligenter, integrierter Energiesysteme. DomLearn soll den Grundstein für die internationale Technologieführerschaft im Bereich von Domain-Informed Machine Learning für Anwendungen in intelligente Energiesysteme legen - sowohl akademisch als auch kommerziell.

## Abstract

The digitization of integrated, regional energy systems leads to the emergence of so-called cyber-physical energy systems,

which are based on the integration of software components and physical processes. In the analysis and optimization of these systems, methods and tools of modeling and simulation are of central importance. The requirements for modeling and simulation have increased due to ever increasing amounts of operational data as well as the blurring of sector boundaries between electricity, gas, heating, cooling and mobility. As a result, established methods of physical and data-driven methods are reaching their respective limits. The development of domain-informed, interpretable, and robust machine learning methods and algorithms (known as Domain-Informed Machine Learning) is considered a radical innovation in the research community.

Arguments for the "why" have been formulated coherently and consistently. The goal of the exploratory project DomLearn is to evaluate for the first time specific applications for Domain-Informed Machine Learning in the field of smart energy systems together with potential users from industry. Furthermore, specific implementations of these applications will be discussed together with international experts. Based on a proof of concepts, selected solutions will be implemented, tested and evaluated.

The project results are intended to enable future projects to be based on an objective and rationally comprehensible evaluation of possibilities and fundamental limitations in the field of Domain-Informed Machine Learning. Thus, the project serves as a preparation for future research and development projects in the area of smart integrated energy systems. DomLearn is intended to lay the foundation for international technology leadership in the field of Domain-Informed Machine Learning for smart energy systems - both academically and commercially.

## **Endberichtkurzfassung**

Traditionelle, auf Physik basierende Ansätze sowie reine datengetriebene Ansätze haben jeweils ihre eigenen Stärken und leiden gleichermaßen unter spezifischen Schwächen. Physics-informed Machine Learning ist ein Ansatz, der Expertenwissen oder grundlegende Prinzipien der Physik, wie Erhaltungsgesetze und physikalische Gleichungen, in maschinelle Lernmodelle integriert, um ihre Vorhersagegenauigkeit und Interpretierbarkeit zu verbessern. Ziel des Sondierungsprojektes DomLearn ist es, erstmals konkrete Anwendungen für Domain-Informed Machine Learning im Bereich intelligenter Energiesysteme zu analysieren. Im Projekt wurden drei Möglichkeiten identifiziert, dieses Wissen integriert werden kann. (i) Wissen über Wahrscheinlichkeiten: A priori Wissen bzw. begründete Annahmen über die Wahrscheinlichkeitsverteilung wichtiger Zufallsvariablen für die Modellierung bilden einen wichtigen Teil von ExpertInnenwissen, welches oft durch Erfahrung gewonnen wird. Für probabilistische Methoden basierend auf Bayes'scher Statistik sind solches Vorwissen bzw. Annahmen ein zentraler Teil der Modellierung und der Vorhersagen. (ii) Strukturelles Wissen, Wissen über kausale Zusammenhänge: Bei der Modellierung komplexer Systeme ist Wissen über Abhängigkeiten zwischen Systemkomponenten unerlässlich. Das gilt speziell für nichtlineare Abhängigkeiten sowie Beeinflussungen, deren Effekt erst nach einer gewissen Latenzzeit beobachtet werden kann. Neben statistischen Korrelationen rückt immer mehr die Untersuchung kausaler Zusammenhänge in den Fokus der Machine Learning Forschung. (iii) Physikalisches Wissen: Ziel ist es, Wissen über physikalische Gesetzmäßigkeiten in ML Modelle wie zu integrieren. Solche Modelle sind in der Lage, komplexe dynamische Systeme lernen. Darüber hinaus führt die Integration physikalischer Gesetze in die Modellarchitektur zu physikalisch plausiblen Modellen.

Im Projekt wurden folgender Forschungsbedarf identifiziert: (a) Es werden generische Frameworks für die Modellierung physischer Systeme benötigt. Dadurch können Domain-Informed ML Ansätze für neue Probleme einfacher und schneller getestet werden. (b) Offene Datensätze und offene Entwicklungen: Um den Mehrwert von Domain-Informed ML-Ansätzen zu

bewerten und an Entscheidungsträger zu kommunizieren, sind praktische Anwendungen (einschließlich offener Daten und Modelle) enorm hilfreich. Hier ist ein Umdenken in der angewandten Forschung erforderlich. (c) Quantifizierung von Unsicherheiten: Neben physikalischer Plausibilität der Ergebnisse ist eine genaue Aussage über die mit den Vorhersagen verbundenen Unsicherheiten eine zentrale Anforderung an moderne, robuste AI Systeme.

## **Projektkoordinator**

- Technische Universität Graz

## **Projektpartner**

- DILT Analytics FlexCo