

KI-PIRINHA

Key enabling technologies on Performance, Efficiency and Resilience by Artificial Intelligence for Hydrogen Applications

Programm / Ausschreibung	FinVn 22/23, Digitale Technologien, AI for Green 2023	Status	laufend
Projektstart	01.04.2024	Projektende	30.09.2026
Zeitraum	2024 - 2026	Projektlaufzeit	30 Monate
Keywords	Hydrogen Application, Safety, Predictive Maintenance, AI based Control, Transfer Learning, Smart Sensor Placement		

Projektbeschreibung

Zur Bewältigung der aktuellen Herausforderungen in den Bereichen Energie und Mobilität sowie industrieller Wärmequellen ist eine erhebliche Steigerung der Nutzung von grünem Wasserstoff als Primärenergiequelle und Speichermöglichkeit erforderlich.

Da Wasserstoff ein hochreaktives Gas ist, sind Maßnahmen zur Sicherstellung der Betriebssicherheit und insbesondere die Vermeidung von katastrophalen Ereignissen (Detonationen) unabdingbar. Der vermehrte Einsatz von Wasserstoffanwendungen erfordert eine gründliche Untersuchung der sicherheitsrelevanten Prozesse bei der Verbrennung. Das Projekt KI-PIRINHA untersucht die erforderlichen Methoden für eine erhöhte Betriebssicherheit, Effizienz und Resilienz von Wasserstoffanwendungen als eine Stütze zur Dekarbonisierung energieintensiver Anwendungen in der Schwerindustrie, der chemischen und petrochemischen Industrie oder der Mobilität. Im Rahmen des Projekts wird ein System zur Überwachung des Zustands der Wasserstoffverbrennung entwickelt, das Methoden des maschinellen Lernens und der Anomalieerkennung umfasst.

Um Daten aus der realen Welt zu sammeln, werden Experimente mit bewusst hervorgerufenen abnormalen Betriebszuständen an unterschiedlich großen H₂ Brennkammern mit einer Nennleistung von bis zu 18 kW als Anwendungsfall durchgeführt. Die realen Daten werden für die Modellidentifizierung und die Erstellung eines Simulationsmodells verwendet, das die Datenaugmentierung und die Erstellung eines hybriden Datensatzes als Trainingsdatensatz ermöglicht. Ein Algorithmus zur frühzeitigen Erkennung von Anomalien dient der Identifizierung von Vorläufern kritischer Betriebszustände, die zu einem katastrophalen Ausfall, z. B. einer Detonation, führen können.

Die Architektur zur Anomalieerkennung ist dabei in zwei separate Teile unterteilt: Ein Modul erkennt Muster der abnormalen Betriebszustände, und bleibt unverändert für verschiedene Brennkammergrößen und -typen. Das zweite Modul bildet die Besonderheiten der Brennkammer ab, so dass für eine Übertragung auf Brennkammern unterschiedlicher Größe lediglich eine minimale Menge an Trainingsdaten erforderlich ist, die auch Konstruktionspezifika enthalten (Transfer Learning). Die Algorithmen werden auf den Prüfständen validiert, um die Effektivität und die Zuverlässigkeit sowie die Eigenschaften des Transfer Learnings zu bewerten.

Abstract

Strategies for current challenges in energy and mobility as well as industrial heat sources require a major increase in utilization of green hydrogen as a primary energy source and storage possibility.

Hydrogen is a highly reactive gas, so focus is put on safety and more particularly on preventing detonation. The leverage of hydrogen applications requires thorough investigation on the safety relevant process involved in the combustion.

The project KI-PIRINHA investigate on required methods for an increased stability, efficiency and resilience of usage of hydrogen as a possibility for decarbonization of energy intensive applications in heavy industry, chemical and petrochemical industry or mobility. Within the project, a health monitoring system for hydrogen combustion is developed that incorporates methods of machine learning/anomaly detection methods.

To gather real world data, experiments are conducted with provoked abnormal operations on differently sized combustion systems with a nominal power of up to 18 kW as a use case. The real-world data is used for model identification and simulation model created, that allows data augmentation and creation of a hybrid dataset as a training dataset. An early anomaly detection algorithm is realized to identify precursors to critical operating conditions potentially resulting in catastrophic failure e.g., detonation.

The Anomaly detection is divided into two separate parts: One module is trained to identify abnormal operation patterns and shall remain constant for various combustor sizes and types. The second module represent combustor specifics, thus a transfer to differently sized combustors only requires a minimal amount of training data includes design specifics (Transfer learning).

Algorithms are validated on the test stands to evaluate performance and detection capabilities as well as Transfer learning efficiency.

Projektkoordinator

- FH JOANNEUM Gesellschaft mbH

Projektpartner

- Combustion Bay One e.U.