

# SAELING:

# SAving Energy by Learning and ImproviNG

# logic-based optimization models



- **Laufzeit:** Mai 2024 – April 2027
- **Konsortialführung:** Universität Klagenfurt, Institut für Artificial Intelligence und Cybersecurity ([aau.at/aics](https://aau.at/aics) | [gerhard.friedrich@aau.at](mailto:gerhard.friedrich@aau.at))
- **Weitere beteiligte Organisationen:**
  - Katholieke Universiteit Leuven Research & Development
  - Siemens Aktiengesellschaft Österreich
  - voestalpine High Performance Metals DIGITAL SOLUTIONS GmbH

Das Forschungsprojekt SAELING wird mithilfe von Methoden des Maschinellen Lernens Vorhersagemodelle generieren, die für das Scheduling in Multi-Objective-Optimierungsproblemen verwendet werden, um energie- und ressourcenschonende Strategien für den industriellen Anwendungsfall der Metallverarbeitung zu finden.

# Anwendungsfall

## Optimierung des Energieverbrauchs in der metallverarbeitenden Industrie

- hoher Energieverbrauch für Sägen, Schleifen, Fräsen
- eine typische Bandsägemaschine verbraucht ~8,4 MWh pro Jahr
- voestalpine serviciert ~2.500 derartige Maschinen  
( $\Sigma$ ~21 GWh pro Jahr, entspricht ca. 5.000 durchschnittlichen Haushalten!)
- Status quo: Energieverbrauch nicht optimiert
- keine ausreichend genauen physikalischen Modelle verfügbar
- SAELING wird Maschinelles Lernen mit Multi-Objective-Optimization kombinieren

# Ziele

- **Ziel 1: Reduktion des Energieverbrauchs**
  - Reduktion der Maschinenzeit durch Anpassung von Parametern wie Geschwindigkeit und Vorschub
  - 20-30% Energieeinsparung sollten noch vor Optimierung des Scheduling möglich sein
- **Ziel 2: Uncertain Multi-Objective Decision-Making**
  - Integration von Aufgabenplanung und Maschineneinstellungen
  - Herausforderung: Unsicherheit der Vorhersagen von ML-Modellen
  - SAELING wird robuste und erklärbare KI-Methoden erforschen
- **Ziel 3: Transfer Learning und Decision-Focused Learning**
  - Lernen von genauen Vorhersagemodellen für den Energieverbrauch
    1. auf Ebene der individuellen Maschine
    2. unterschiedliche Maschinen / Maschinenkonfigurationen (“transfer learning”)
    3. das gesamte Optimierungs-/Scheduling-Problem (“decision-focused learning”)
  - Verbesserung von Energieeffizienz, CO<sub>2</sub>-Emissionen, Schmiermittelverbrauch, ..., Total Cost of Ownership



**All das mit Beachtung zukünftiger Übertragbarkeit auf andere Anwendungsfälle...**

z.B. in der Fertigung, im Smart-City-Bereich, bei Stromnetzen, ...