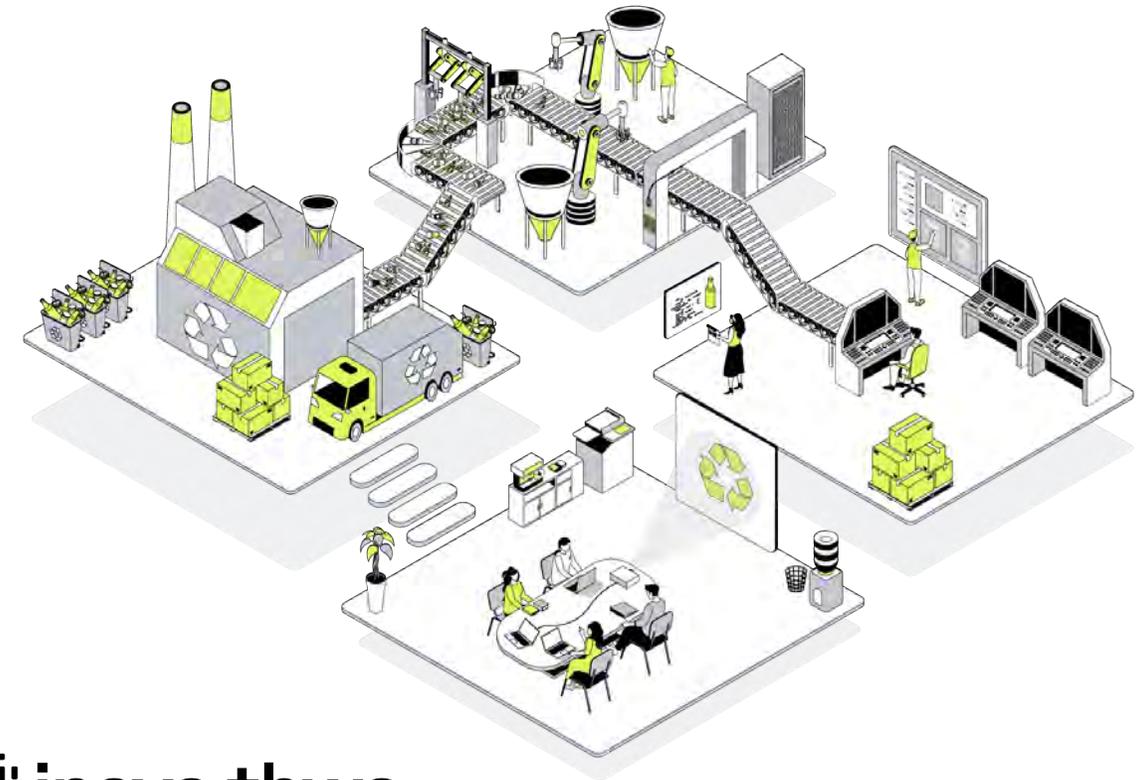




Energieeffiziente Auftragsplanung

enefit Webinar 10.07.2025



Agenda

- 1 Teamvorstellung
- 2 Projektziele und Fokusthemen
- 3 Energieverbrauch von CNC Maschinen anhand des NC-Codes vorhersagen
- 4 Vermeidung von Lastspitzen in der Auftragsplanung
- 5 Veranstaltungen & nächste Schritte

Team



Anna-Maria Schmitt



Eddi Miller



Maria Celia Briones
Espinoza



Matthias Zipf



Prof. Dr. Fabian Scheller



Prof. Dr. Miguel
Gonzalez-Salazar



Prof. Dr. Jürgen
Hartmann



- 8 Laufende Projekte
- 18 Wissenschaftl. Mitarbeitende
- 5 Forschungsprofessoren

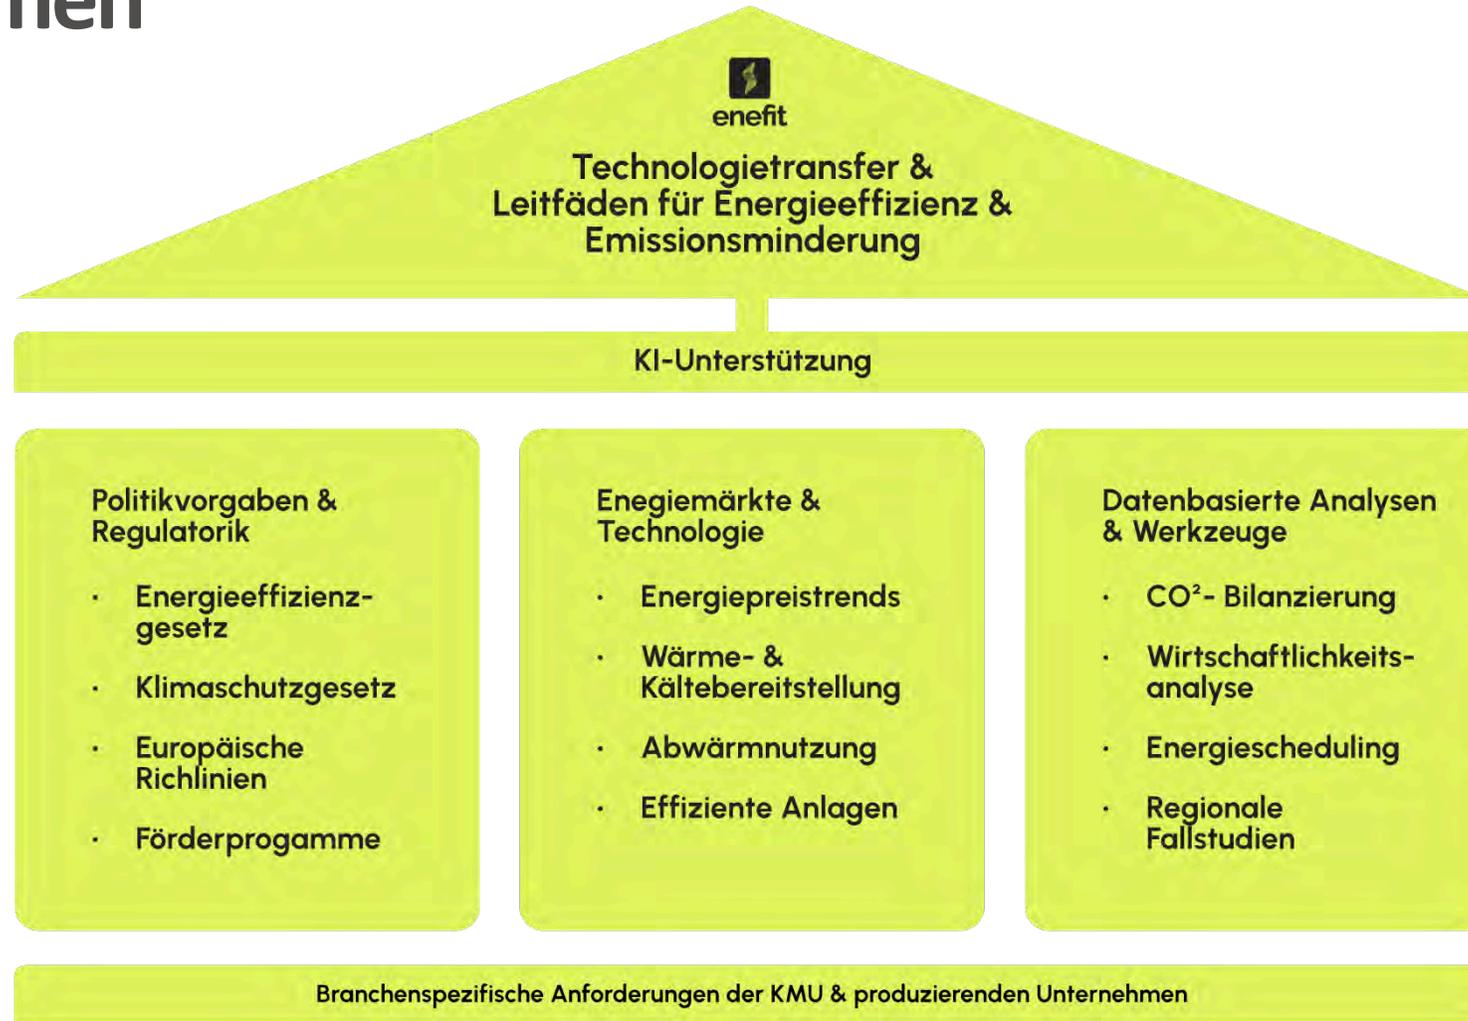
Projektziele



Unterstützung von KMUs & produzierendem Gewerbe in Mainfranken bei der Umsetzung von Energieeffizienz- & Dekarbonisierungsmaßnahmen

- Förderung von Vernetzung & strategischer Zusammenarbeit
- Kommunikation regulatorischer Anforderungen & Markttrends
- Erarbeitung praxisnaher & regionaler Fallstudien
- Sensibilisierung für nachhaltige Technologien
- Bereitstellung digitaler Werkzeuge und Leitfäden für die Praxis

Fokusthemen



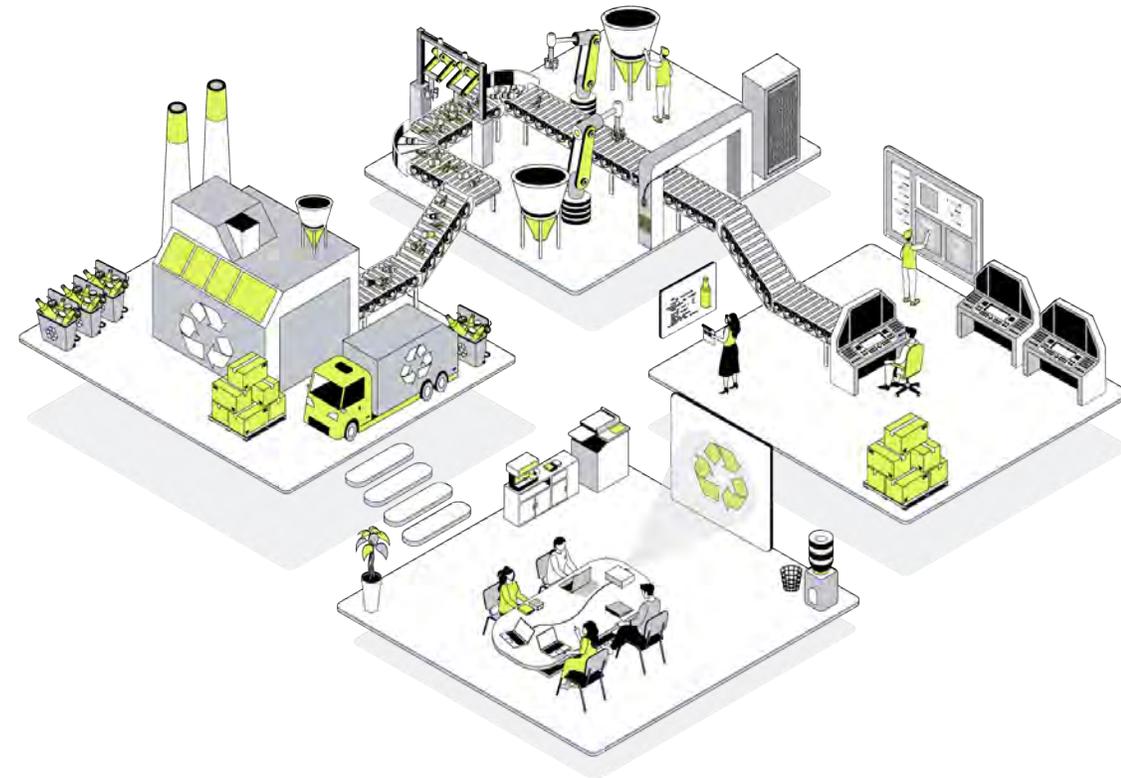
Beteiligte Unternehmen





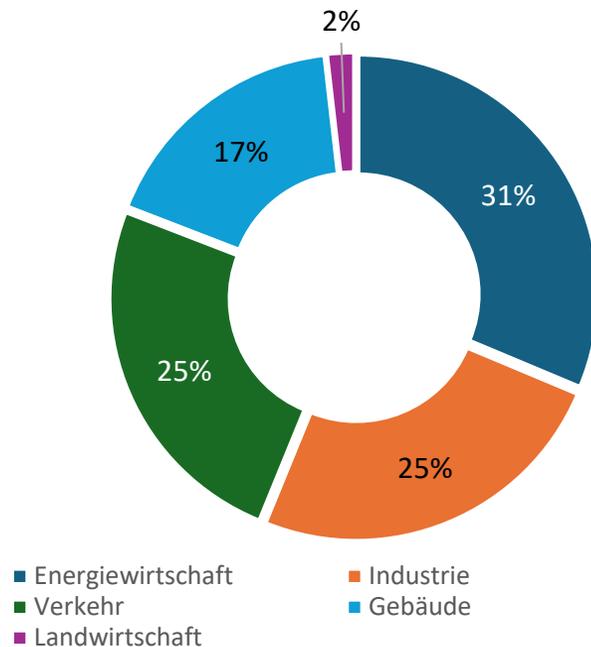
enefit

Energieverbrauch von CNC-Maschinen



Motivation

CO₂ Emissionen in Deutschland

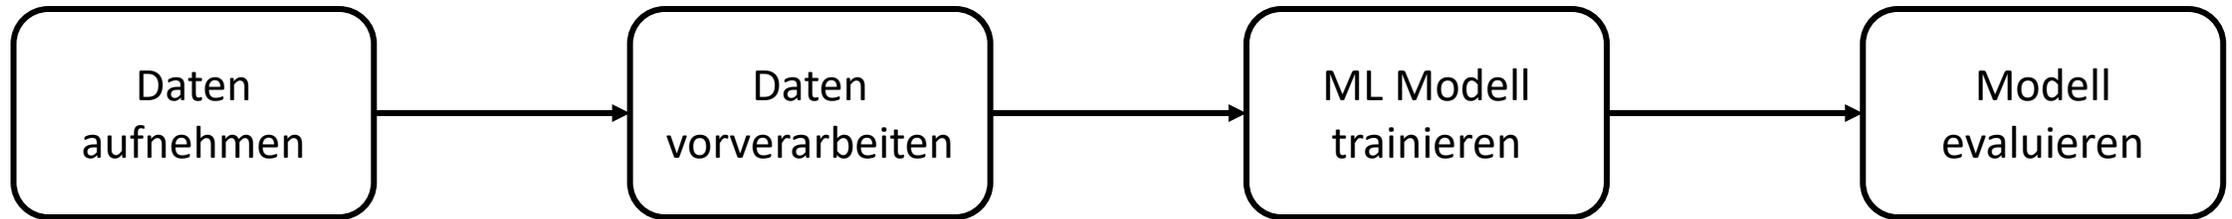


- Die verarbeitende Industrie verursacht rund 24 % der CO₂-Emissionen in Deutschland.
- Die Energiekosten der CNC-Bearbeitung machen 1-6 % der gesamten Bearbeitungskosten aus.
- Der Energieverbrauch eines Produkts kann für die Auftragsplanung oder die Berechnung des CO₂-Fußabdrucks des Produkts verwendet werden.
- Diese Energieverbrauchsvorhersage erfolgt vor der Produktion eines Teils und basiert auf dem NC-Code

Umweltbundesamt. (14. März, 2025). Verteilung der CO₂-Emissionen in Deutschland nach Quellgruppe im Jahr 2024 [Graph]. In Statista.

Eine präzise Vorhersage ermöglicht eine optimierte Auftragsplanung und Energieeinsparungen, direkt aus dem NC-Code

Vorgehen



Vorgehen

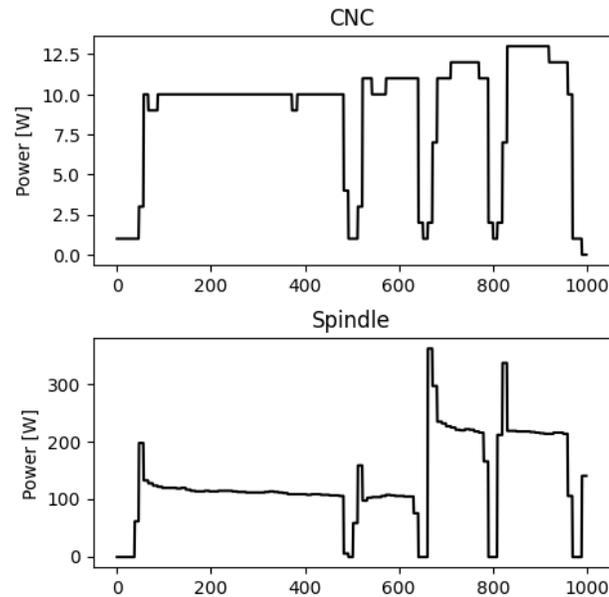
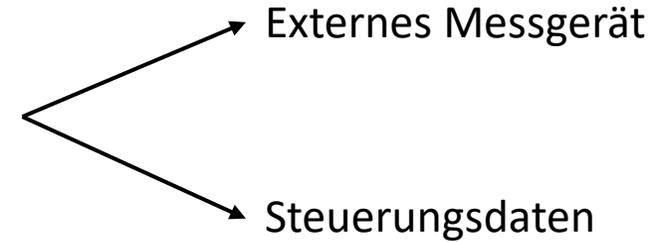
Daten aufnehmen

G-code erstellen

```
G-code
N210 T="ENTFRAESER D8_N_90GRAD"
N220 M6
N250 SUPA G0 Z=610.
N260 SUPA G0 X-365. Y224. B0.0 C0.0
N330 G0 X-10.46 Y-22. Z16. S10345 M3
N340 G1 Z0.0 F2069.
N350 X-14.54
N360 G3 X-15.84 Y-24. I0.0 J-1.3
```

- G00: Schnelle Bewegung ohne Bearbeitung
- G01: Geradlinige Bearbeitung
- G02/G03: Kreisförmige Bearbeitung

Leistungsdaten aufnehmen



Vorgehen

Daten
vorverarbeiten

G-code in Features
umwandeln

Gefahrenre Strecke der
Spindel bestimmen

Energieverbrauch pro
Zeile bestimmen

G-code

```
N210 T="ENTFRAESER_D8_N_90GRAD"  
N220 M6  
N250 SUPA G0 Z=610.  
N260 SUPA G0 X-365. Y224. B0.0 C0.0  
N330 G0 X-10.46 Y-22. Z16. S10345 M3  
N340 G1 Z0.0 F2069.  
N350 X-14.54  
N360 G3 X-15.84 Y-24. I0.0 J-1.3
```

Features

G	X	Y	Z	B	C	I	J	Feed rate	Spindle speed	Tool diameter	Spindle on	Traveled distance	Energy consumption
6										8			10
0			610									610	15.5
0	-365	224		0	0							428.3	5
0	-10.46	-22	16						10345		True	734.2	7.2
1			0					2069				16	8.7
	-14.54											14.5	2.9
3	-15.84	-24				0	-1.3					25.7	22.1

Vorgehen

ML Modell
trainieren

Machine Learning Modelle auswählen

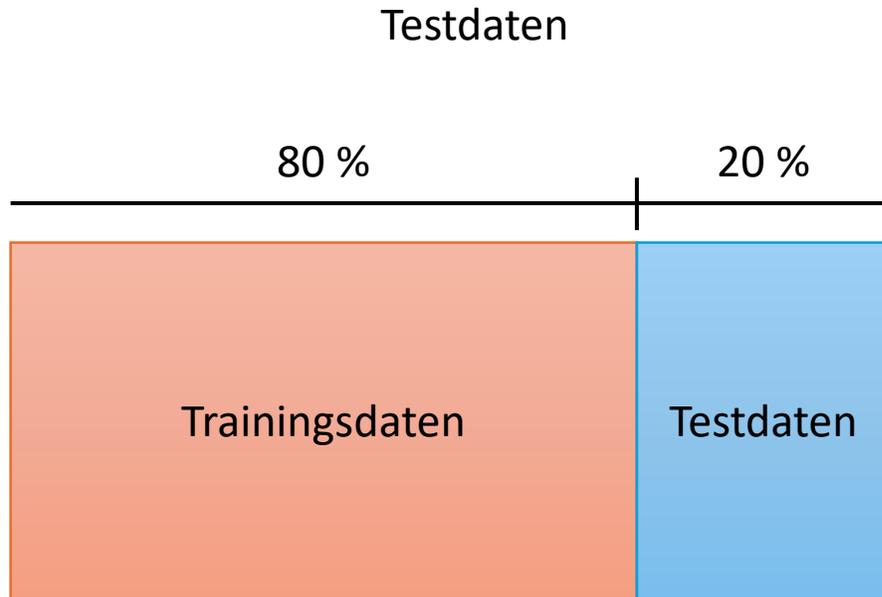
- Neuronale Netze
- Decision Tree Algorithmen (Random Forest, LightGBM, CatBoost, XGBoost)

Metriken auswählen

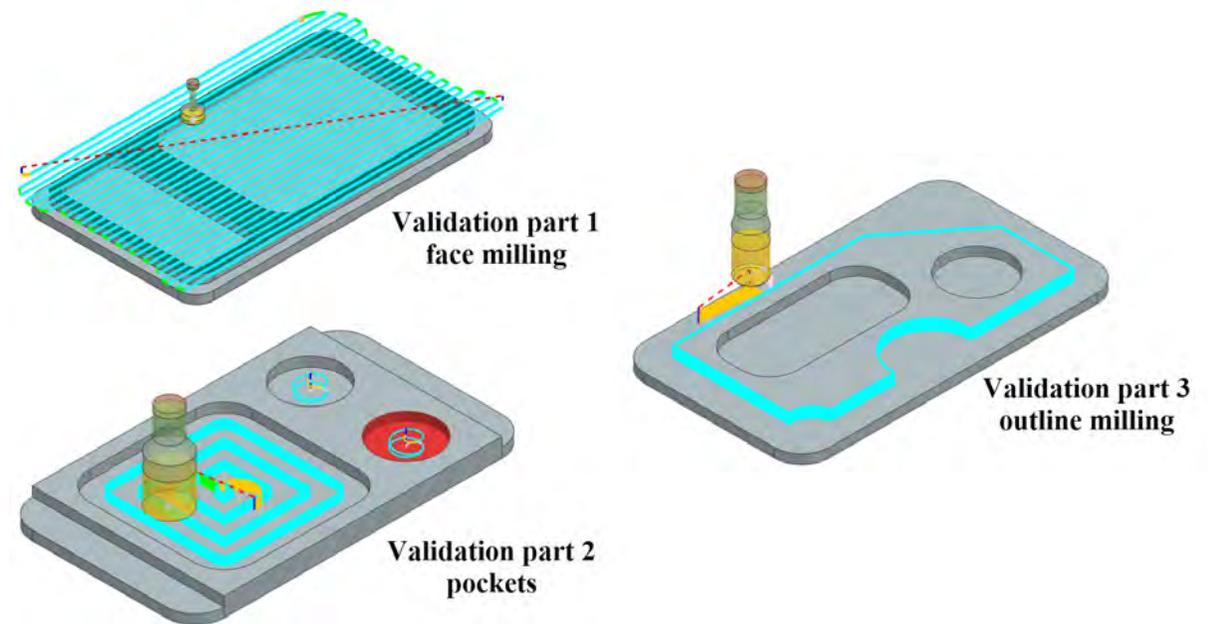
- Mean absolute error (MAE) = $\frac{1}{N} \sum_{n=1}^N |x_n - \hat{x}_n|$
- Root mean square error (RMSE) = $\sqrt{\frac{1}{N} \sum_{n=1}^N (x_n - \hat{x}_n)^2}$
- Mean absolute percentage error (MAPE) = $\frac{1}{N} \sum_{n=1}^N \left| \frac{x_n - \hat{x}_n}{\hat{x}_n} \right|$
- $R^2 = 1 - \frac{\sum_{n=1}^N (x_n - \hat{x}_n)^2}{\sum_{n=1}^N (x_n - \bar{x})^2}$

Vorgehen

Modell
evaluieren



Validierungsteile



Maschinen + Messgeräte



Stepcraft M1000, 3 Achsen

Chauvin Arnoux PEL103

- Gesamtleistung
- 10 Datenpunkte pro Sekunde

Softing uaGate 840D

- Leistung für alle Achsen (X, Y, Z, B, C, Spindel, Werkzeugwechsel)
- ca. 2 Datenpunkte pro Sekunde
- Auch andere Maschinenparameter auslesbar



Spinner U-620, 5 Achsen

Modellinputs

Features													
G	X	Y	Z	B	C	I	J	Feed rate	Spindle speed	Tool diameter	Spindle on	Traveled distance	Energy consumption
6										8			10
0			610									610	15.5
0	-365	224		0	0							428.3	5
0	-10.46	-22	16						10345		True	734.2	7.2
1			0					2069				16	8.7
	-14.54											14.5	2.9
3	-15.84	-24				0	-1.3					25.7	22.1

Modell für alle G-Befehle

- Gefahrene Strecke der Spindel
- Spindeldrehzahl
- Werkzeugdurchmesser
- Vorschubgeschwindigkeit
- G-Befehl

Einzelne Modelle für verschiedene G-Befehle

G00:

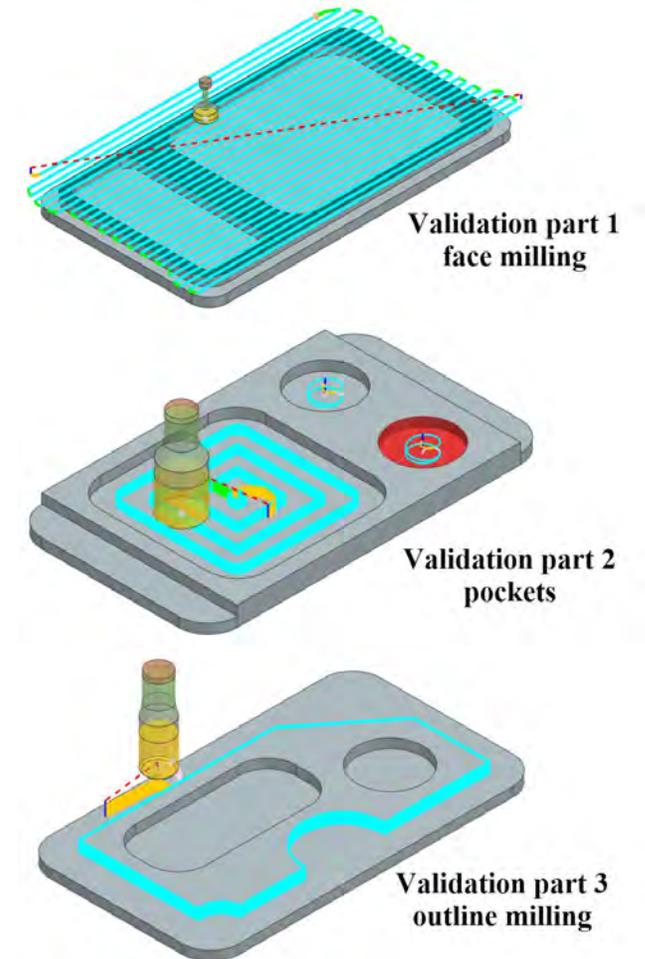
- Gefahrene Strecke der Spindel
- Spindeldrehzahl

G01, G02/G03:

- Gefahrene Strecke der Spindel
- Spindeldrehzahl
- Werkzeugdurchmesser
- Vorschubgeschwindigkeit

Vorgehen Stepcraft M1000

- Einzelne Modelle für verschiedene G-Befehle
 - Zufällig generierte Punkte, die angefahren werden
 - 1400 G-code Zeilen
 - Experimente ohne Werkstück
 - 80 % Trainingsdaten, 20 % Testdaten
 - Validierung mit 3 Teilen
 - Auswahl des besten Modells durch vorausgegangene Tests
- Neuronale Netze



Modellergebnisse Stepcraft M1000

Testdaten

	MAE	RMSE	MAPE	R2
G00	27.88	45.16	0.10	0.98
G01	177.51	539.51	0.07	0.96
G02	286.94	949.87	0.09	0.78
Total	166.53	619.02	0.09	0.92

Validierungsteile

	Total Energy [J]		Error	
	Actual	Predicted	Absolute [J]	Relative [%]
Part 1	346621.45	474227.94	127606.49	36.81
Part 2	331464.00	328835.87	2628.13	0.79
Part 3	523242.80	388166.90	135075.90	25.82

Wichtigste Inputfeatures:

- Spindeldrehzahl
- gefolgt von gefahrene Strecke für G00 und G02
- und Vorschubgeschwindigkeit bei G01

Vorgehen Spinner U-620

- Einzelne Modelle für verschiedene G-Befehle werden mit einem Modell für alle G-Befehle verglichen
 - Reale Teile
 - Experimente mit Werkstück
 - 80 % Trainingsdaten, 20 % Testdaten
 - Validierung mit 9 Wiederholungen eines Teils
 - Auswahl des besten Modells durch vorausgegangene Tests
- Decision Tree Algorithmen

Trainingsteile



Validierungsteil



Modellergebnisse Spinner U-620

Testdaten

Total		
G00	MAE	744.69
	RMSE	1863.18
	MAPE	0.30
	R ²	0.22
G01	MAE	604.60
	RMSE	1554.97
	MAPE	0.30
	R ²	0.70
G02	MAE	702.56
	RMSE	1912.12
	MAPE	0.21
	R ²	0.89
All	MAE	915.61
	RMSE	3028.04
	MAPE	0.35
	R ²	0.55

Validierungsteil, einzelne Modelle für G-Befehle

	AE	RAE
1	336568.36	0.68
2	380070.86	0.72
3	173618.22	0.72
4	342691.11	0.84
5	406085.15	0.77
6	247701.62	0.54
7	305175.07	0.65
8	377932.00	0.71
9	324537.77	0.70
Mean Energy	408167.11	0.72

Validierungsteil, gemeinsames Modell für G-Befehle

	AE	RAE
1	140558.63	0.28
2	179033.49	0.34
3	33113.11	0.14
4	192906.90	0.47
5	254331.90	0.48
6	60072.67	0.13
7	146281.11	0.31
8	150034.29	0.28
9	101846.69	0.22
Mean Energy	207749.05	0.37

Wichtigste Inputfeatures:

- Strecke und Vorschubgeschwindigkeit
- Werkzeugdurchmesser und Spindeldrehzahl

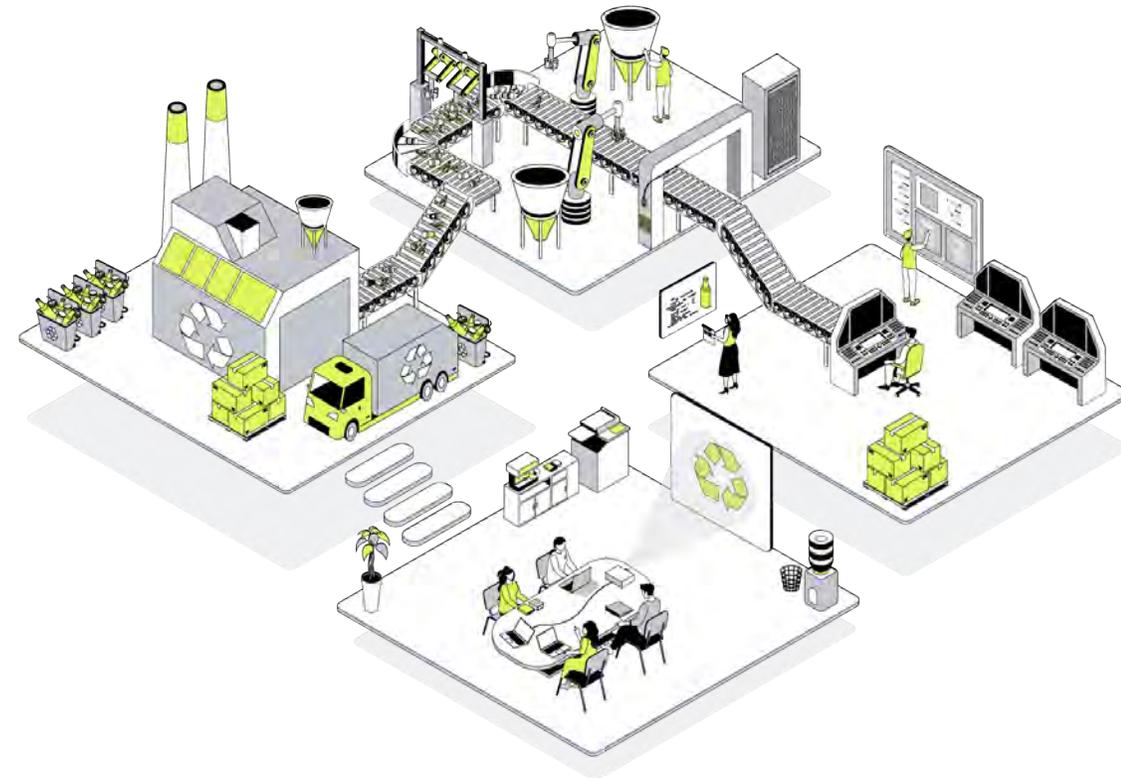
Fazit

- Energieverbrauch kann **vor der Produktion** abgeschätzt werden
- Ergebnisse können für **Auftragsplanung** und CO₂ – Fußabdruckberechnung genutzt werden
- Integration in CAM-/MES-System denkbar



enefit

Energieeffiziente Auftragsplanung



Job Shop Scheduling – Auftragsplanung

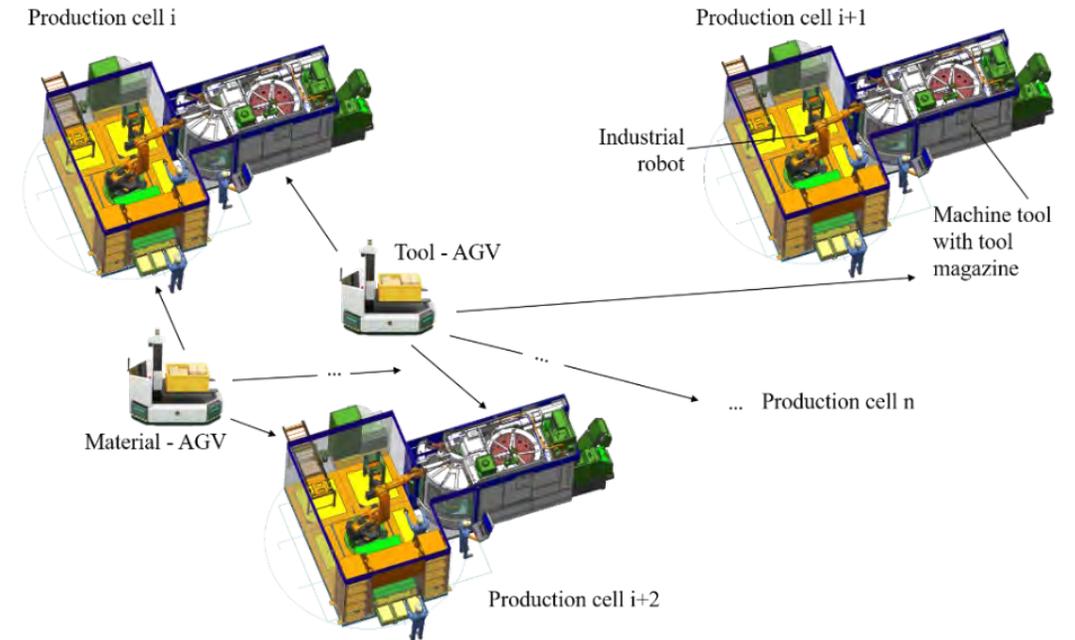
Die Planung von hochautonomen Produktions- bzw. Roboterzellen erfordert die Integration und Koordination komplexer Systeme in dynamischen Umgebungen.

Optimierung und Effizienz:

- Effiziente Zuweisung der verschiedenen Ressourcen Maschine, Roboter und AGV um Kosten und Durchlaufzeit zu minimieren

Flexibilität und Adaptivität:

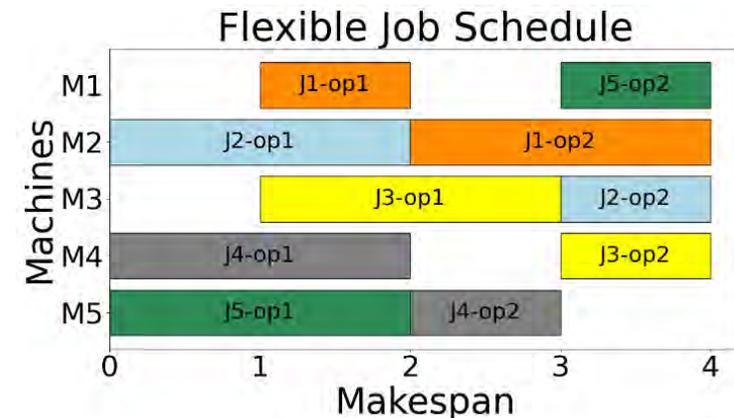
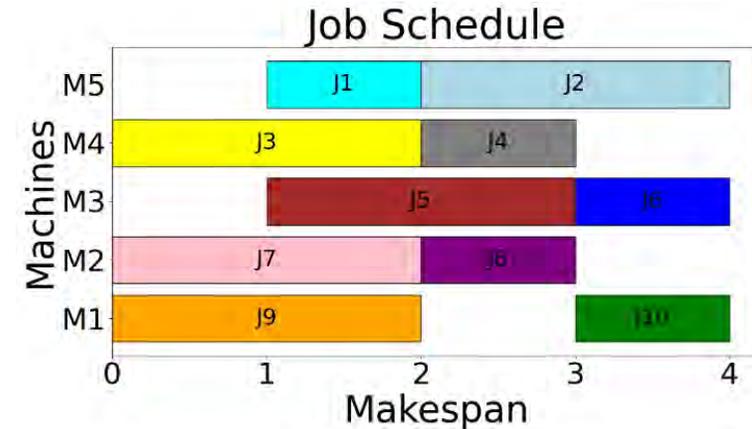
- Hochautonome Systeme müssen in der Lage sein, sich an veränderte Produktionsbedingungen, neue Aufträge oder unerwartete Ereignisse anzupassen



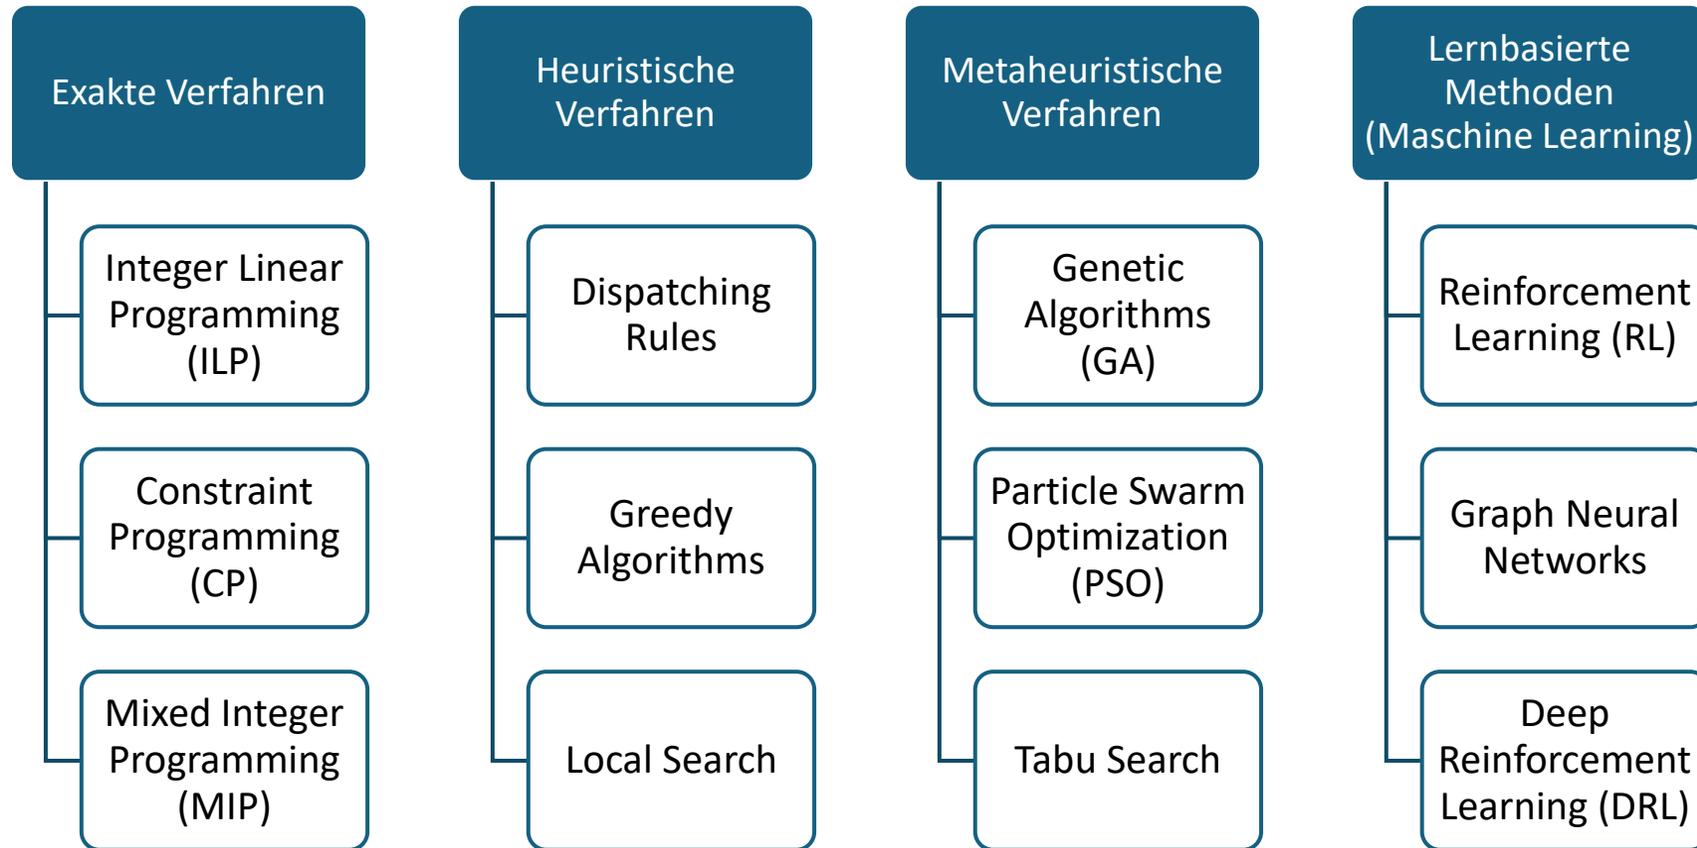
Job Shop Scheduling – Auftragsplanung

- Klassisches Job Shop Scheduling (JSS) beinhaltet die Planung von Fertigungsaufträgen auf mehrere Maschinen
- Ziel ist die Optimierung der Durchlaufzeit (makespan)

- Flexible Job Shop Scheduling (FJSS) unterteilt die Aufträge in Operationen was durch verschiedene Abhängigkeiten zu einer höheren Komplexität führt
- Ziel ist auch hier die Optimierung der Durchlaufzeit (makespan)



Methoden zur Lösung des FJSS



Festlegen von Rahmenbedingungen

Typische Constraints im Flexible Job Shop Scheduling:

- 1. Operationale Reihenfolge: Operationen eines Jobs müssen in definierter Reihenfolge ausgeführt werden.
- 2. Maschinenzuweisung: Jede Operation kann auf mehreren Maschinen ausgeführt werden, wird aber nur einer zugewiesen.
- 3. Maschinenkapazität: Eine Maschine kann zu einem Zeitpunkt nur eine Operation verarbeiten.
- 4. Bearbeitungszeiten: Bearbeitungszeiten können je nach Maschine variieren.
- 5. Kein Unterbrechungen: Operationen dürfen nicht unterbrochen und später fortgesetzt werden.
- 6. Deadlines & Due Dates: Einige Jobs müssen innerhalb eines Zeitrahmens abgeschlossen werden.
- 7. Ressourcenrestriktionen: Begrenzte Verfügbarkeit von Arbeitskräften, Werkzeugen, Energie etc.

Festlegen von Rahmenbedingungen

Typische Constraints im Flexible Job Shop Scheduling:

- 1. Operationale Reihenfolge:

$$S_{i,n} < S_{i,n} + D_{RC} < F_{i,n}$$

- 2. Maschinenzuweisung:

- 3. Maschinenkapazität:

$$S_{i,n+1} > F_{i,n} \quad \forall n < P$$

$$\min_{Makespan} = \sum_{i=1}^n J_i$$

$$\min_{VarE} = \frac{\sqrt{Var(E)}}{\mu}$$

MEPSO – Micro Evolutionary Particle Swarm Optimization

Was ist MEPSO?

- Eine Weiterentwicklung der klassischen Particle Swarm Optimization (PSO)
- Verwendet eine kleine Population ('Micro Swarm') und integriert evolutionäre Operatoren wie Mutation und Selektion
- Ziel: Erhöhung der Diversität und Vermeidung von Premature Convergence

Warum besser als klassisches PSO?

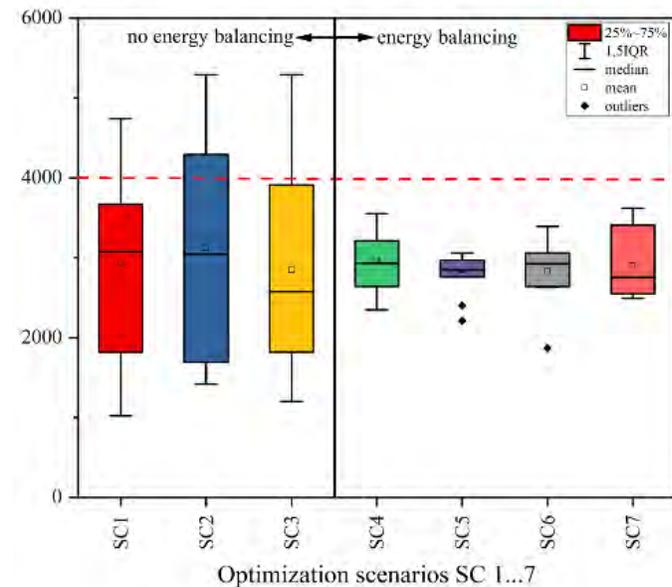
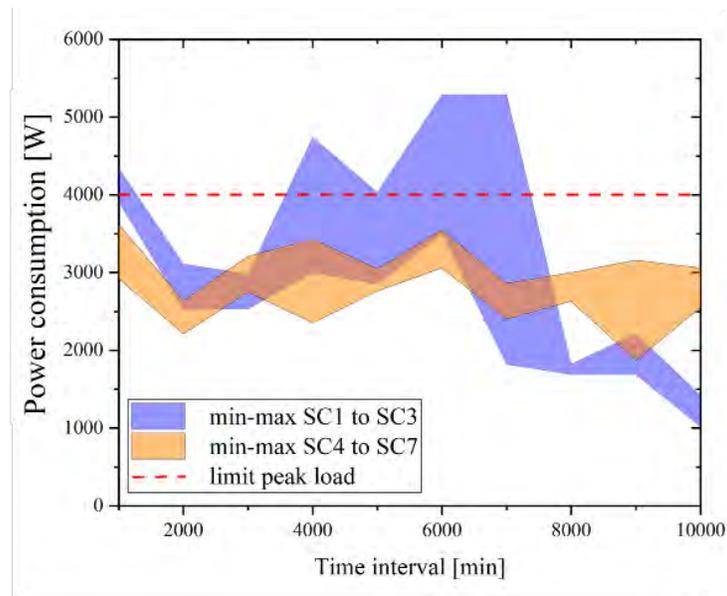
- Höhere Effizienz bei kleinen Populationsgrößen
- Bessere Exploration des Suchraums durch Mutation
- Höhere Konvergenzgeschwindigkeit bei komplexen Optimierungsproblemen
- Robuster gegenüber lokalen Minima

Typische Anwendungsbereiche:

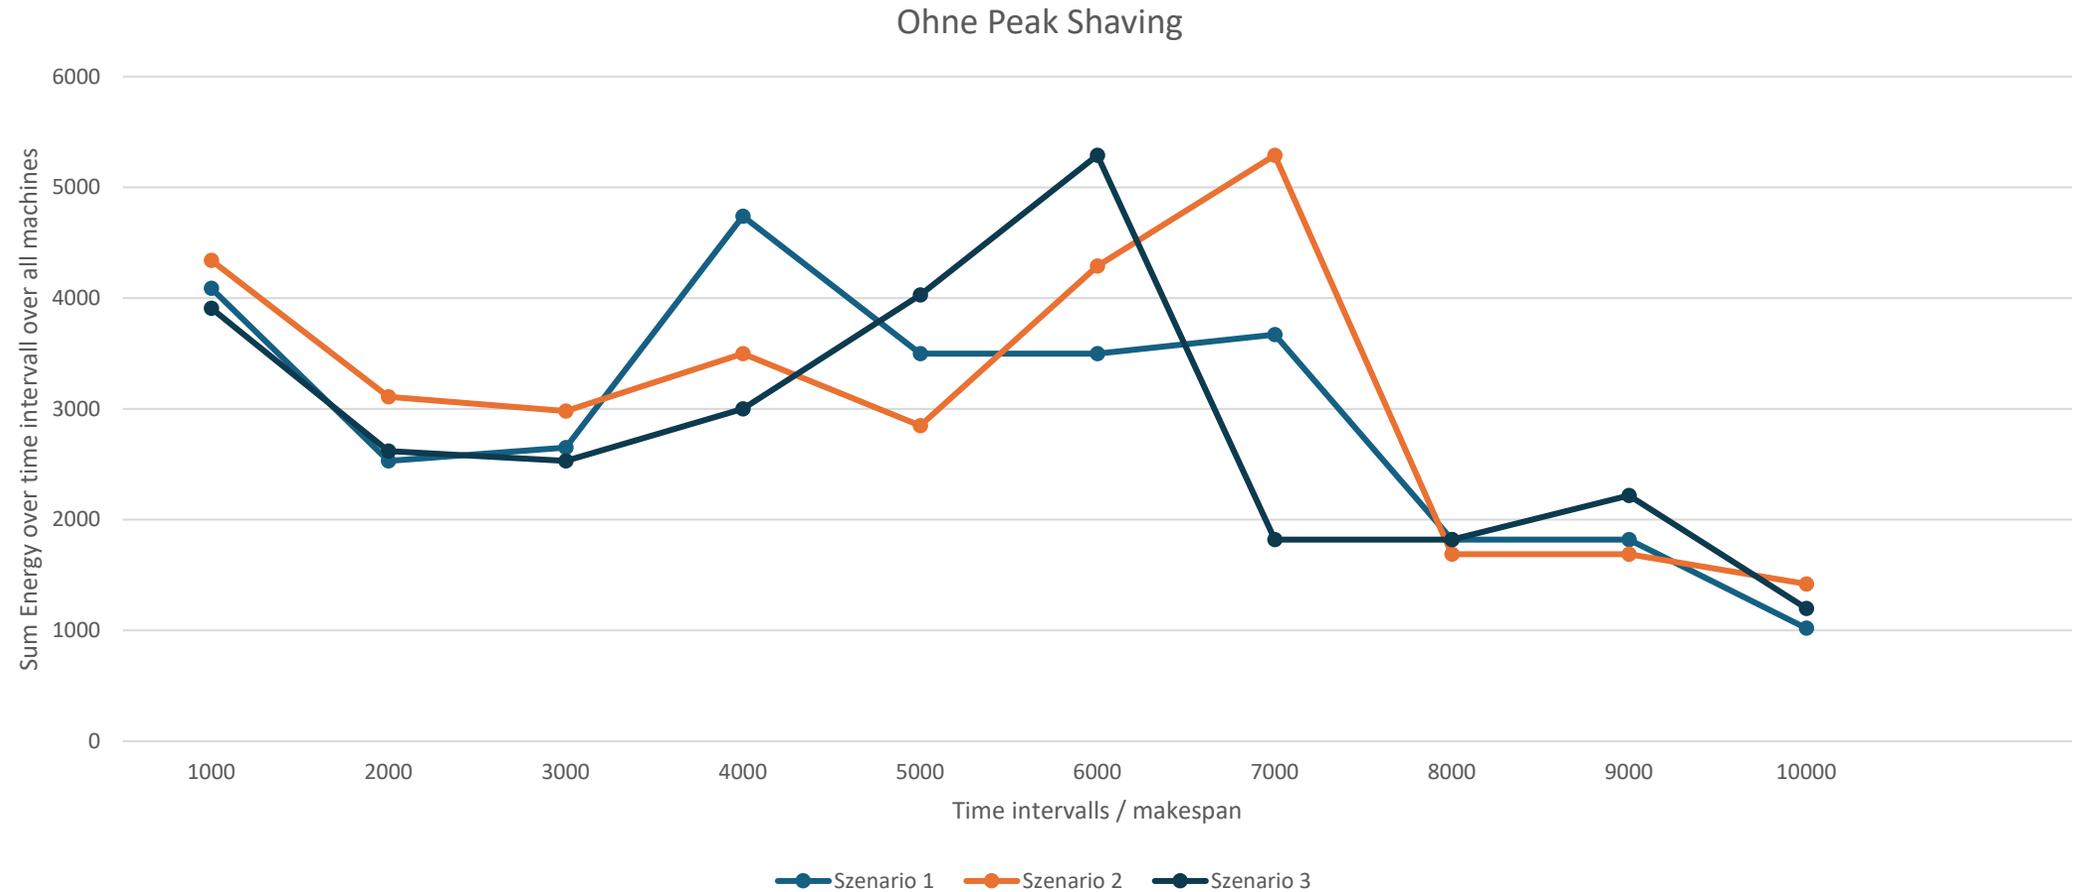
- Scheduling (z. B. Flexible Job-Shop Scheduling)
- Parameteroptimierung
- Multimodale Optimierungsprobleme

Anwendung von MEPSO zum Peak Shaving

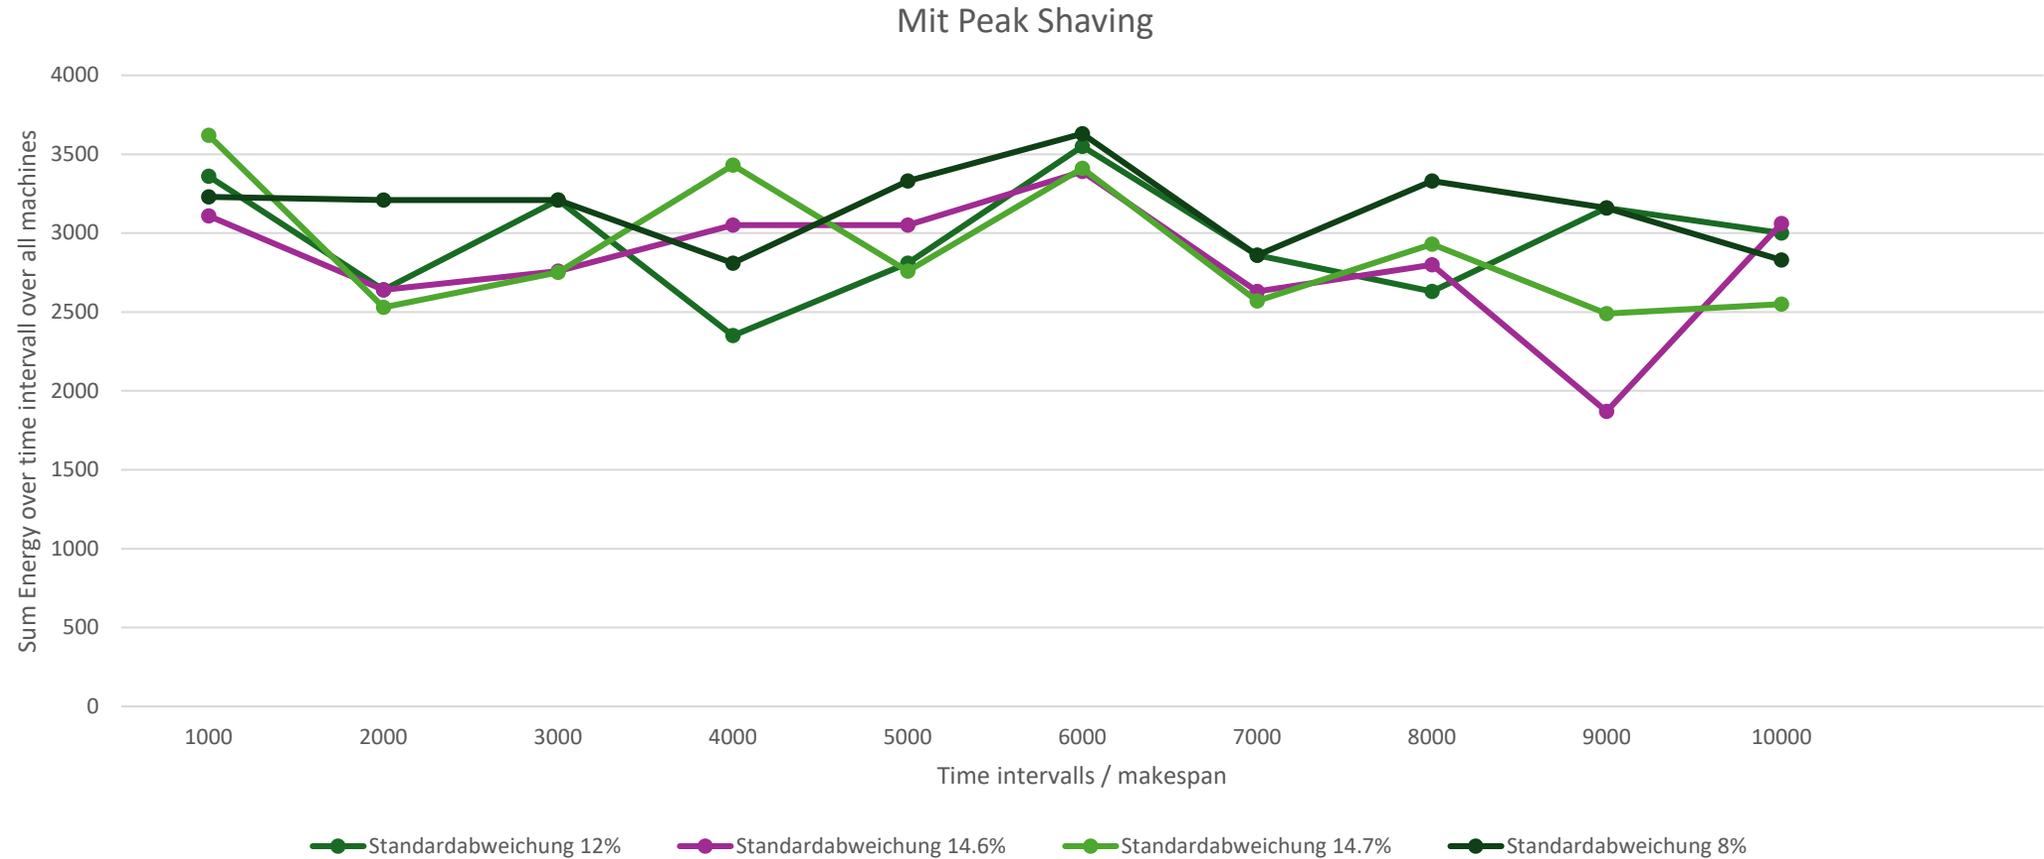
- Test mit insgesamt 7 Szenarien, 3 ohne Peak Shaving und 4 mit Peak Shaving
- 16 Fertigungsaufträge pro Szenario
- 3 Maschinen die parallel arbeiten



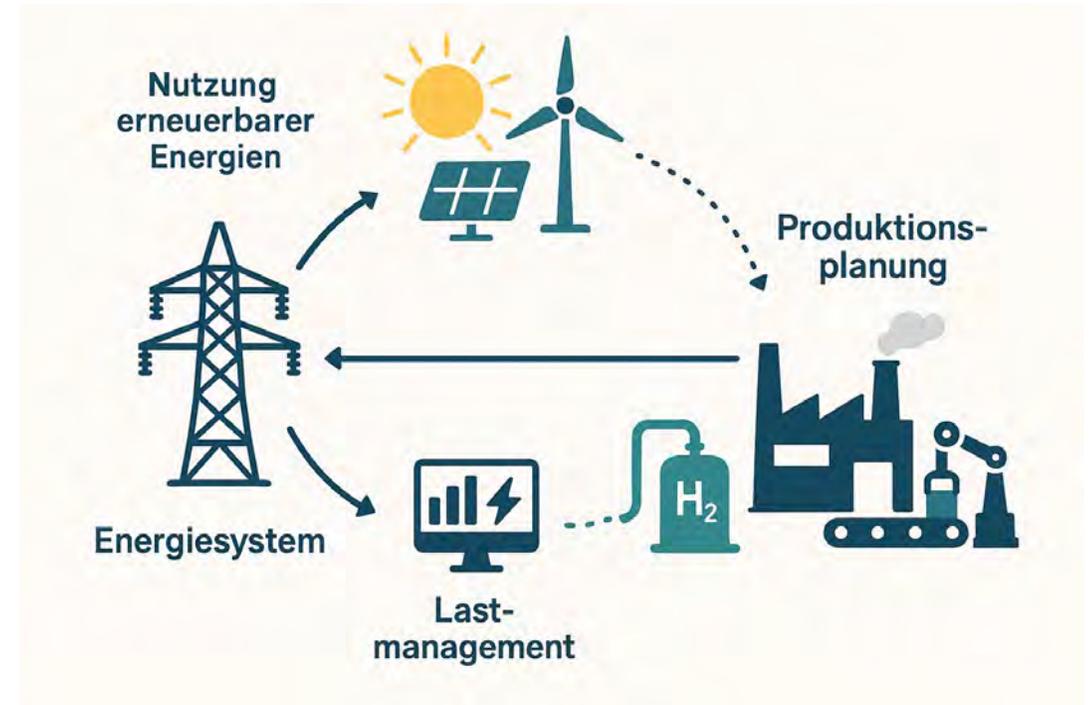
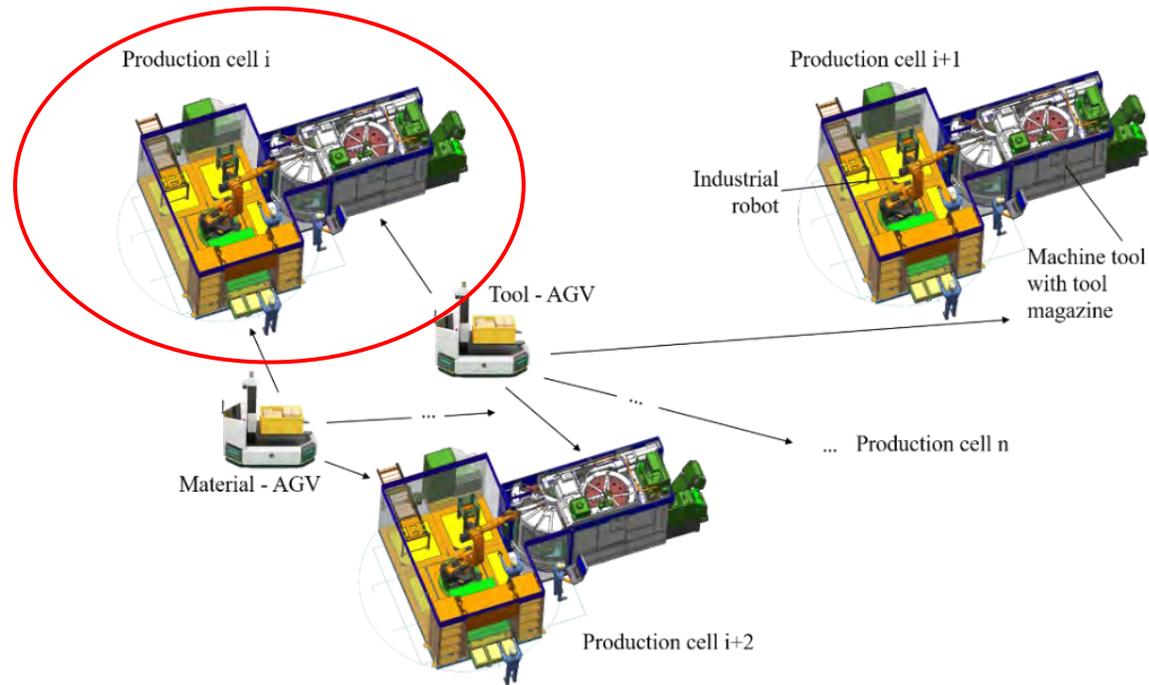
Anwendung von MEPSO zum Peak Shaving



Anwendung von MEPSO zum Peak Shaving



Ausblick FJSS, Peak Shaving und Energiesysteme



Veranstaltungen & nächste Schritte

09 OKT
2025

CO2 Fußabdruck und Dekarbonisierung
Workshop

6 NOV
2025

Vorstellung des Chatbots
Webinar

Kooperationsvertrag

 Bayerisches Staatsministerium für Wissenschaft und Kunst 

Kooperationsvereinbarung

zwischen

Hochschule	Technische Hochschule Würzburg-Schweinfurt (THWS)
------------	---

und

Unternehmen	
Adresse	
Zustimmung zur Veröffentlichung des Sitzes und Namens unseres Unternehmens auf der Projekthomepage	<input type="checkbox"/> Ja <input type="checkbox"/> Nein

Die Parteien bestätigen, dass sie am durch den Europäischen Fonds für regionale Entwicklung (EFRE) geförderten Projekt

Projektname: ENEFIT - Digitaler Leitfaden für KMUs zur technischen Umsetzung des EU Green Deal und des Energieeffizienzgesetzes

Laufzeit: 01.06.2024 - 31.05.2027

im Rahmen des operationellen Programms im Ziel „Investition in Wachstum und Beschäftigung“ Bayern 2021 – 2027 unter nachfolgenden Bedingungen teilnehmen werden.

- Die Koordination des Projektes erfolgt durch die Hochschule.
- Durchführung der Zusammenarbeit und Berichterstattung:
 - Jeder Projektpartner ist für die Durchführung seiner Arbeiten entsprechend der Projektbeschreibung selbst verantwortlich.

Kein Projektpartner in ihrer Verantwortung zu verpflichten, eine ungleiche Erstattung der Leistungen sind

des Projektes

ke der lich geschützten

haben

! ein nicht res, kostenloses (die keine Rechte besitzt, und Fähigkeiten von geben, werden in uren zugeordnet.

Je auf frei zugängliche offene Software

Danke!

Wir freuen uns auf die
Zusammenarbeit.

Für Fragen zum Projekt oder bei
Interesse an einer Teilnahme besuchen
Sie uns auf www.enefit.ai oder
kontaktieren Sie uns gerne unter:
enefit.insys@thws.de



enefit