



# MOTIUS

WE R&D.

Angebot

**AB-250926.4-51612.12**

SEW-EURODRIVE GmbH & Co KG  
23.12.2025 11:07 (0536ec2)



# **Agile Time & Material Contract**

Zwischen den Vertragsparteien

und

SEW-EURODRIVE GmbH & Co KG  
Ernst-Bickle-Str. 42  
76646 Bruchsal, DE

Motius GmbH  
Walter-Gropius-Straße 17  
80807 München, DE

im Nachfolgenden Auftraggeber genannt

im Nachfolgenden Auftragnehmer genannt.

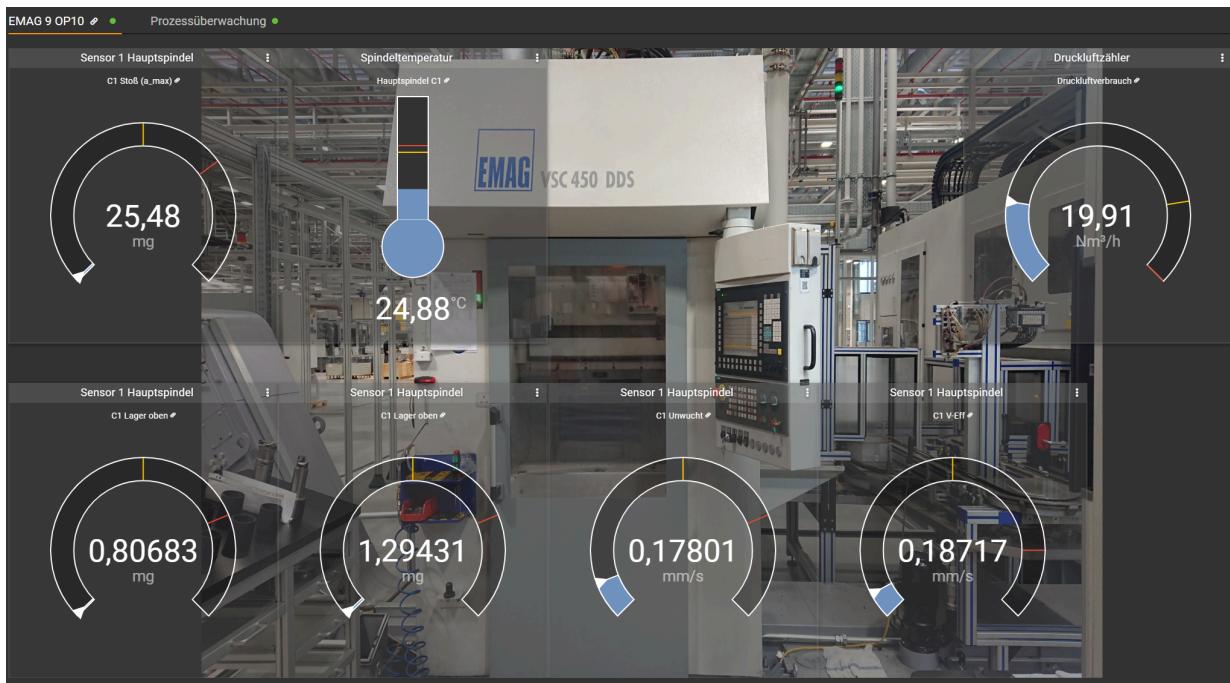
# Projektplan

## SpindelCheck

### Status Quo

Die derzeitigen Wartungspraktiken für Spindeln bei SEW sind hauptsächlich reaktiv und präventiv ausgelegt und verfügen nicht über fortgeschrittene Predictive-Maintenance-Fähigkeiten. Spindelausfälle führen häufig zu ungeplanten Produktionsstillständen, beeinträchtigen die Betriebseffizienz und erhöhen die Wartungskosten.

In den letzten zehn Jahren hat SEW IFM-Sensoren in Verbindung mit der IFM Moneo-Plattform für die manuelle Spindelüberwachung eingesetzt.



Diese Lösung liefert zwar wertvolle Daten, erfordert jedoch erhebliche manuelle Eingriffe und ermöglicht keine automatisierte Früherkennung potenzieller Ausfälle.

Die aktuellen Wartungsstrategien umfassen:

- Geplante vorbeugende Wartung in festen Intervallen
- Reaktive Reparaturen nach Spindelausfällen
- Manuelle Inspektionen und Diagnosetests

Diese Ansätze bringen mehrere Herausforderungen mit sich:

- Unerwartete Ausfallzeiten aufgrund unerkannter Spindelprobleme

- Suboptimale Zuteilung von Wartungsressourcen
- Eingeschränkte Fähigkeit zur genauen Schätzung der verbleibenden Nutzungsdauer (RUL) von Spindeln

Ein Übergang zu vorausschauender, datengesteuerter Wartung ist erforderlich, um diese Einschränkungen zu beheben und die Gesamtzuverlässigkeit der Anlagen zu verbessern.

## Ziel

Implementierung einer IIoT-basierten Predictive-Maintenance-Lösung zur Spindelüberwachung mit folgenden Zielen:

- Erfassung hochauflösender Sensordaten für die Spindelzustandsanalyse, idealerweise unter Verwendung vorhandener Sensoren
- Kontinuierliche Überwachung des Spindelzustands
- Implementierung von Anomaly Detection und Ausfallvorhersage
- Reduzierung ungeplanter Ausfallzeiten durch Frühwarnsystem
- Schaffung der Grundlage für einen potenziellen flächendeckenden Rollout und robuste Predictive-Maintenance-Strategie
- Optimierung der Wartungspläne basierend auf dem tatsächlichen Zustand
- Bereitstellung umsetzbarer Erkenntnisse über eine benutzerfreundliche Schnittstelle

## Stand der Technik

Es gibt viele bestehende AI / Machine-Learning-Ansätze zur Überwachung rotierender Maschinen und zur Vorhersage von Ausfällen:

Ansatz	Beschreibung	Automatisierungsgrad	Analytics	ML/AI Nutzung
Traditional Condition Monitoring	Periodische Vibrationsanalyse mit Handmessgeräten	Manuell	Einfach (Stichproben)	Keine
Continuous Monitoring Systems	Installierte Sensoren mit einfachen Schwellenwert-Alarmen	Halbautomatisiert	Schwellenwertbasierte Alarne	Keine
AI-based Predictive Maintenance	ML-Modelle trainiert auf historischen Ausfalldaten	Automatisiert	Predictive Analytics	Supervised & Unsupervised ML

AI-based Predictive Maintenance nutzt tendenziell die meisten Signale zur Vorhersage von Ausfällen, darunter:

1. Vibrationsanalyse (Frequency Domain Analysis, FFT)
2. Temperaturüberwachung
3. Akustische Emissionsmessung
4. Strom-/Leistungsüberwachung
5. Machine Learning für Anomalieerkennung
6. Remaining Useful Life (RUL) Vorhersage

Von diesen ist Vibration das dominierende Signal für die Spindelgesundheit. Die erfolgreichsten RUL-Systeme basieren auf Beschleunigungssensordaten (rohe Zeitreihen plus Envelope / Spectral Transforms). Time-Domain-Statistiken (RMS, Kurtosis) und Envelope-Spectrum-Features werden nach wie vor häufig als starke, interpretierbare Indikatoren verwendet.

Time-Frequency-Representations & CNNs sind ein sehr effektiver Pattern-Recognition-Ansatz. Die Umwandlung von Fenstern in STFT/CWT/Spectrogram-Images und das Training von CNNs (oder CNN → LSTM Hybrids) liefert starke Performance bei Bearing/Spindle-Aufgaben, insbesondere beim Umgang mit komplexen Vibrationssignaturen. Neuere Ansätze kombinieren CNNs mit Sequence Models (Bi-LSTM) oder Variational Autoencodern für robuste Feature Extrahierung.

Recurrent Models werden weiterhin häufig eingesetzt. Sequence Models (LSTM / Bi-LSTM / Transformers) behandeln temporale Abhängigkeiten gut. Transformers und Wavelet-Self-Attention-Hybrids werden für längere Abhängigkeiten und Cross-Sensor-Fusion erforscht und übertreffen LSTMs in Benchmarks oft, wenn genügend Daten verfügbar sind.

State-of-the-Art-Arbeiten kombinieren zunehmend Methoden (z.B. CNN → Transformer, CNN + VAE + BiLSTM), um starke lokale Feature Extraction mit temporaler Modellierung und Unsicherheitsschätzung zu verbinden. Diese Hybrids schneiden bei komplexen Multi-Sensor-Datensätzen tendenziell am besten ab.

Phase	Ziel
<b>Datenvorbereitung &amp; Qualitätsbewertung</b>	Daten verstehen und bereinigen
<b>Datenstrukturierung &amp; Failure Mapping</b>	Daten organisieren, RUL definieren
<b>Feature Exploration &amp; Signal Validation</b>	Auf prädiktive Degradation prüfen
<b>Feature Engineering</b>	Aussagekräftige Input-Features erstellen
<b>RUL Modeling</b>	Modelle trainieren, validieren und interpretieren
<b>Auswertung &amp; Präsentation</b>	Machbarkeit und Ergebnisse zusammenfassen

*Mögliche Entwicklungsphasen einer Predictive-Maintenance-Lösung*

## Lösungsvorschlag

Um die Predictive-Maintenance-Lösung in die bestehenden Systeme von SEW zu integrieren, werden Sensordaten in eine Analytics-Plattform eingespeist, wo Preprocessing, Feature Extraction und Machine-Learning-Algorithmen angewendet werden.

Zur Erfassung hochauflösender Daten bis zu 100 kHz, die für fortgeschrittene Vibration Analysis benötigt werden können, wird Motius direkte Verbindungen zu IFM-Sensoren über

industrielle Protokolle (z.B. OPC-UA, MQTT, Modbus, Serial Connection) untersuchen, sofern unterstützt, oder Edge-Computing-Geräte nutzen, um rohe Sensordaten zu erfassen und abzuspeichern.

Alternativ könnte der vorhandene [VSE100](#) kurze Bursts von rohen Daten bei hohen Sampling-Raten aufzeichnen, die dann periodisch getriggert und zur Analyse abgespeichert werden können.

Falls direkter Hochfrequenz-Datenzugriff mit IFM-Sensoren nicht machbar ist, wird das Team Montronix-Sensoren evaluieren.

Zusätzliche Hardware kann bei Bedarf in Betracht gezogen werden, um die Data-Acquisition-Anforderungen zu erfüllen.

Um sicherzustellen, dass die erfassten Daten für die beabsichtigten Analysen geeignet sind, wird das Projektteam eng mit SEW zusammenarbeiten, um sicherzustellen, dass Sensorplatzierungen, Konfigurationen und Datenqualität den Anforderungen der Predictive-Maintenance-Modelle entsprechen. Dies kann die Validierung von Sensorkalibrierung, Sampling-Raten und Datenintegrität sowie die Definition von Messverfahren umfassen.

Daten werden entweder on-premise bei SEW, oder in SEW's Microsoft Fabric Umgebung abgespeichert.

## Prozessintegration

In der Explorationsphase wird das Projektteam eng mit SEW zusammenarbeiten, um aktuelle Prozesse zu verstehen und Integrationspunkte für Predictive-Maintenance-Fähigkeiten zu identifizieren.

Das Projektteam wird die bestehenden Wartungsprozesse von SEW abbilden, um Folgendes zu identifizieren:

- Geplante Wartungsintervalle und Entscheidungskriterien
- Reaktive Wartungsauslöser und Reaktionsverfahren
- Datenquellen, die derzeit für Wartungsentscheidungen verwendet werden (manuelle Inspektionen, Moneo-Alarme, Wartungsprotokolle)
- Wichtige Stakeholder und Kommunikationskanäle
- Dokumentations- und Berichtsanforderungen

## Datenerfassung

Parallel zur Prozessbewertung evaluiert das Projektteam die Datenerfassung von IFM und / oder Montronix-Sensoren. Das Team wird validieren, dass die gesammelten Daten eine ausreichend hohe Auflösung und Qualität bieten.

## Pilotsystem

Ein Pilotsystem wird parallel zu bestehenden Prozessen entwickelt und läuft nebenher, ohne größere Änderungen zu erfordern:

- **Data Recording:** Einige Maschinen mit IFM / Montronix-Sensoren werden ausgestattet, um kontinuierlich rohe Sensordaten aufzuzeichnen und abzuspeichern (on-premise oder Cloud, in Absprache mit SEW's IT)
- **Parallel Validation:** Predictive Insights werden mit Wartungsteams zur Validierung gegen tatsächliche Spindelbedingungen geteilt, lösen aber während des PoC keine direkten Wartungsaktionen aus
- **Feedback Loops:** Regelmäßige Kollaborationssitzungen zum Vergleich von Modellvorhersagen mit beobachtetem Spindelverhalten und Wartungsergebnissen
- **Alert Refinement:** Iterative Anpassung der Detection-Sensitivität basierend auf operativem Feedback, um False Positives zu minimieren und gleichzeitig sicherzustellen, dass kritische Probleme erkannt werden

## Übergangsplanung

Basierend auf den Erkenntnissen aus dem Pilotsystem wird gemeinsam mit SEW definiert:

- Wie Predictive Alerts in die bestehende Wartungsplanung integriert werden sollen
- Rollen und Verantwortlichkeiten für das Monitoring und die Reaktion auf System-Insights
- Erforderliche Dokumentation für Wartungspersonal
- Integrationspunkte mit bestehenden IT-Systemen
- Eskalationsverfahren für kritische Alarme

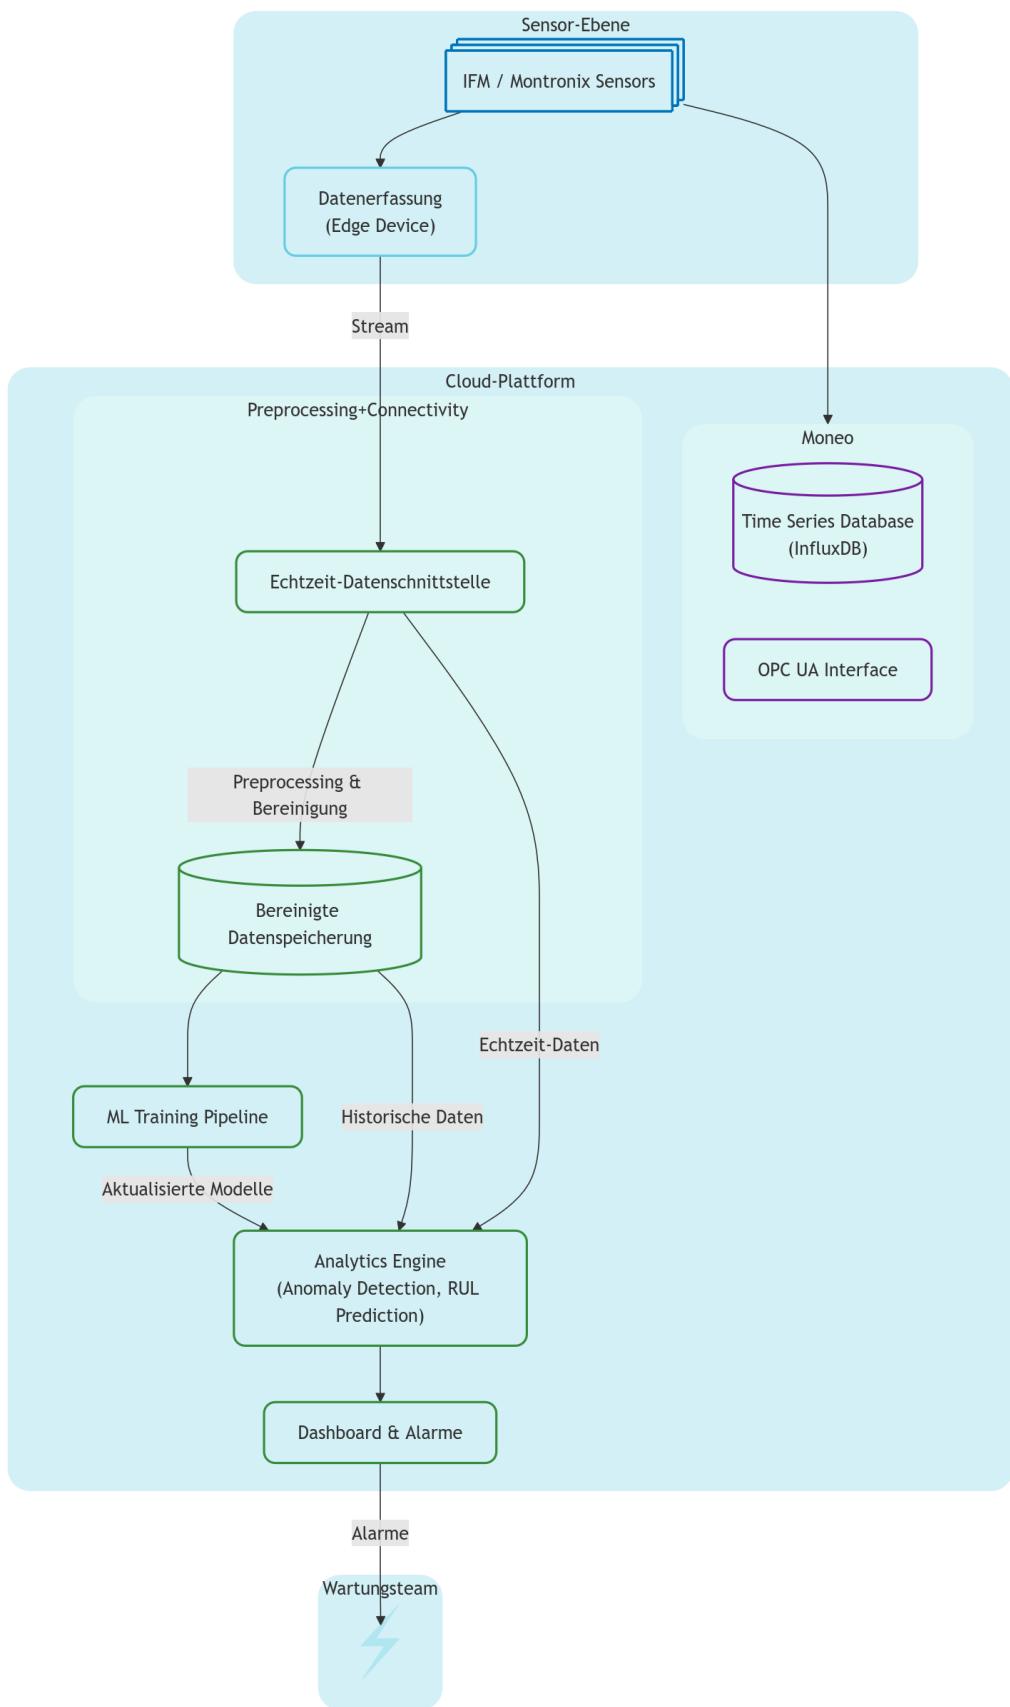
Dieser kollaborative Ansatz stellt sicher, dass die finale Lösung mit den operativen Realitäten von SEW übereinstimmt und mit minimaler Störung übernommen werden kann.

## **Systemkonzept**

Die Systemarchitektur besteht aus drei Hauptebenen:

1. Sensoren & Data Acquisition
2. IT Software Platform
3. User Interface für die Wartung

Während die Sensor-Hardware die Grundlage der Datenerfassung bildet, ist die IT Platform für Datenspeicherung, Preprocessing und fortgeschrittene Analytics verantwortlich. Das User Interface zeigt Alarne und Ergebnisse der Vorhersagen aus unserem Modell, vor allem für SEW's Wartungsteam.



IT Systeme können entweder on-premise auf einer virtuellen Maschine deployt werden, oder ein SEW's Cloud Umgebung. Folgende Funktionen müssen bereitgestellt werden:

- Langfristige Datenspeicherung und Trendanalyse
- ML-Modelltraining auf historischen Daten
- Flottenweite Analytics über mehrere Maschinen
- Optimierung der Predictive-Maintenance-Planung

Die ML Modelle werden voraussichtlich folgende Algorithmen verwenden:

- Anomaly Detection mit Autoencodern, LSTMs, Random Forests, XGBoost etc.
- Remaining Useful Life (RUL) Prediction mit CNNs, LSTMs, Transformers etc.
- Pattern Recognition für spezifische Ausfallmodi (z.B. Bearing Wear, operative Probleme)
- Physical Simulation gekoppelt mit Machine-Learning-Algorithmus

## Vorgehen

Das Projekt beginnt mit einer ersten explorativen Phase, die sich auf das Verständnis der aktuellen Spindel-Wartungsabläufe konzentriert, wichtige Ausfallmodi identifiziert und verfügbare Sensordaten erfasst & evaluiert. Diese Phase umfasst die Machbarkeitsanalyse und Entwicklung einer Proof-of-Concept-Pipeline für Anomaly Detection. Die gewonnenen Erkenntnisse leiten das Design und die Implementierung der Predictive-Maintenance-Lösung und stellen die Ausrichtung an operativen Anforderungen und technischen Anforderungen sicher.



### Datenerfassung

Die Projektdauer hängt von der Geschwindigkeit der Datenerfassung ab. Das Training eines Machine-Learning-Modells zur Erkennung von Spindelausfällen erfordert Testdaten, die mehrere Ausfälle umfassen. Da Spindelausfälle relativ selten sind, kann es einige Zeit dauern, bis genügend Daten gesammelt sind.

## 1 Data Acquisition & Machbarkeitsstudie

Das Projektteam erfasst Daten, prüft deren Qualität und trainiert dann aktuelle State-of-the-Art Machine-Learning-Modelle auf diesen Daten. Da die Daten von zwei Spindeln mit bekannten Austausch-Events stammen, besteht das primäre Ziel darin, festzustellen, ob messbare Degradationsmuster vor Ausfällen existieren.

Der Ansatz beinhaltet eine explizite **Machbarkeits**-Phase, um zu bestätigen, dass verfügbare Daten prädiktive Degradationssignale enthalten, bevor die vollständige Modellentwicklung

erfolgt.

#### Risiken:

Risiko	Auswirkung	Mögliche Maßnahmen
Datenqualität der Sensoren ist nicht ausreichend	Mittel	Validierung der Sensorkalibrierung, Implementierung zusätzlicher Datenqualitätsprüfungen, Evaluation alternativer Sensoren (z.B. Montronix)
Spindelausfälle sind selten, der Datensatz enthält zu wenige "Nicht-iO" Signale um ein effektives Modell zu trainieren	Mittel	Verwendung von Anomaly-Detection-Ansätzen, Augmentierung mit synthetischen Daten, Transfer Learning von ähnlichen Systemen, längere Datenerfassungsphase
Technische Herausforderungen bei der Akquise von Rohdaten aus den existierenden Sensoren	Mittel	Nutzung von Edge-Geräten für direkte Sensoranbindung, Burst-Recording mit VSE100, Evaluation alternativer Sensoren (z.B. Montronix)

#### Ergebnisse:

- Validierte ML-Modelle für Anomaly Detection und RUL Prediction
- Machbarkeitsbewertungsbericht mit Degradationsmuster-Analyse
- Alert-System-Konzept und Threshold-Empfehlungen
- Feature-Engineering-Dokumentation
- Wartungsrichtlinien basierend auf Model-Insights



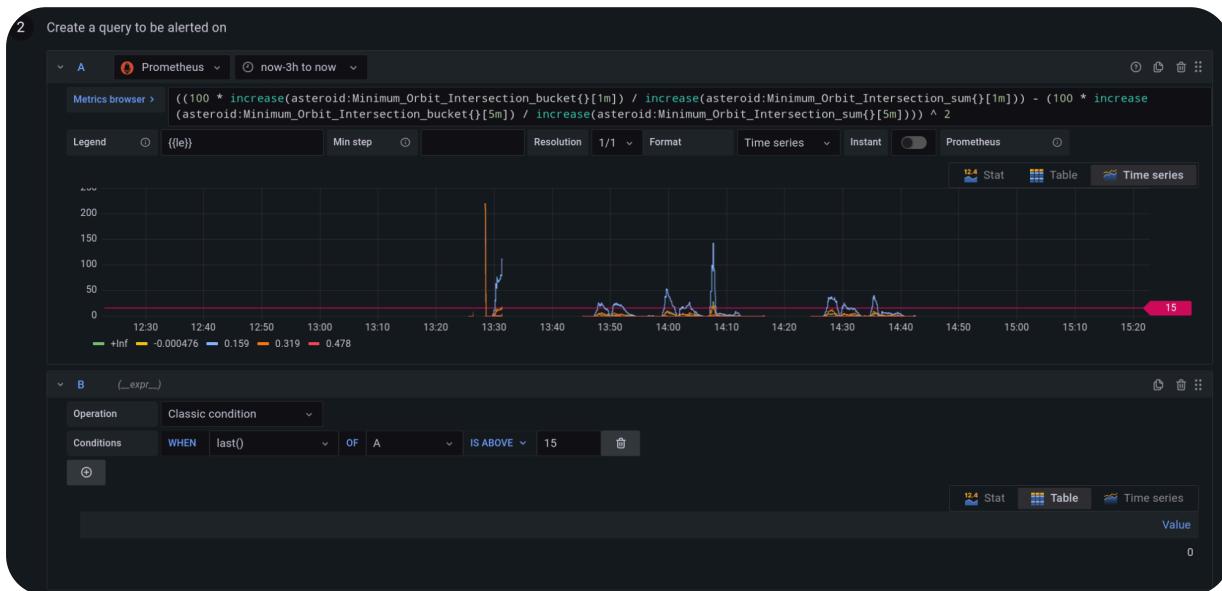
#### Machbarkeitsprüfung

Nach dem **Machbarkeits** Meilenstein können SEW & Motius gemeinsam entscheiden, ob die verbleibenden Phasen basierend auf den Ergebnissen fortgesetzt werden sollen.

Motius schätzt Kosten von **ca. 25.000€** für diese Machbarkeits-Phase.

## ② Pilotsystem & Testing

Motius deployt und testet das Prediction System in einer kontrollierten Umgebung, während immer mehr rohe Sensordaten gesammelt werden, die für das Training fortgeschrittener Modelle verwendet werden können.



Grafana ist ein Open-Source Data-Visualization-Tool zur Exploration roher Daten, Anzeige von Modellvorhersagen und Versendung von Alarmen

### Ergebnisse:

- Pilotsystem in SEW's Infrastruktur
- Real-time Data-Ingestion-Pipeline von rohen Sensordaten
- User-Dashboard mit Monitoring- und Alerting-Fähigkeiten
- Pilottest-Bericht mit Performance-Metriken und User-Feedback
- System-Dokumentation und technische Spezifikationen

## ③ Rollout & Validation

Mit den Erkenntnissen aus der Pilotphase geht das Projektteam zum vollständigen Deployment auf der Fertigungsfläche über. SEW muss die Maschinen mit den notwendigen Sensoren ausstatten, während Motius das IT-Deployment unterstützt, die Modellverfeinerung fortsetzt und bei Bedarf zusätzliche Hardware für Edge Computing bereitstellt.

The screenshot shows the mlflow UI interface. At the top, there's a navigation bar with 'mlflow' logo, version '3.2.1.dev0', and links for 'GitHub' and 'Docs'. Below the header, there's a sidebar with 'Experiments' (selected), 'Models', and 'Prompts'. The main content area has tabs for 'Runs', 'Models', 'Experimental' (selected), 'Evaluation' (with a dropdown for 'Traces'), and 'Traces' (selected). A search bar and filter dropdown are at the top of the table. The table is titled 'Assessments (7/7)' and has columns: Trace ID, Request, Execution time, Request time, State, concise\_compliance, follows\_instructions, includes\_next\_step, mentions\_code, professional\_code, and Relevance. Each row contains a summary of metrics (e.g., PASS 9%, FAIL 91%) and detailed pass/fail counts for each assessment category.

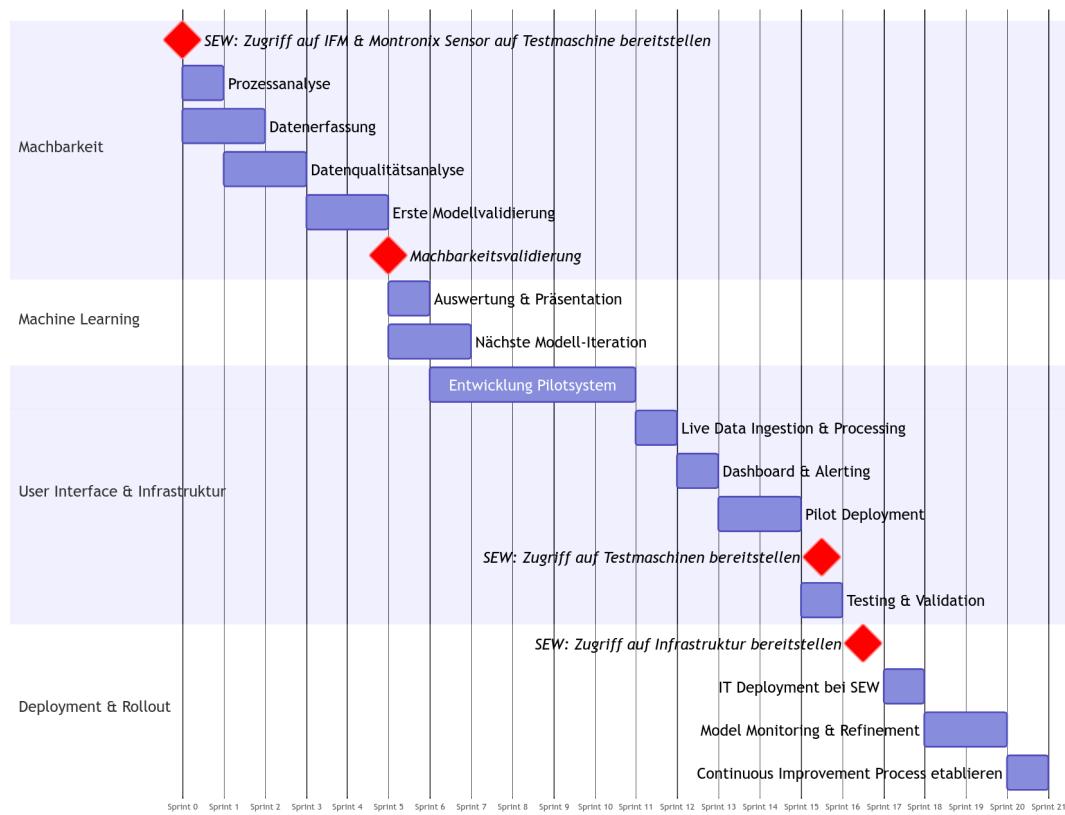
Trace ID	Request	Execution time	Request time	State	concise_compliance	follows_instructions	includes_next_step	mentions_code	professional_code	Relevance
		PASS 9%	PASS 64%	PASS 0%	PASS 100%	PASS 100%	PASS 100%	PASS 100%	PASS 100%	PASS 100%
tr-2971ea...	{ "customer_name": "Acme Corp", ... }	4.976s	3 days ago	OK	Fail	Pass	Fail	Pass	Pass	Pass
tr-9df173...	{ "customer_name": "TechStart", "u..."}	4.492s	3 days ago	OK	Fail	Fail	Fail	Pass	Pass	Pass
tr-b468d9...	{ "customer_name": "Acme Corp", "..."}	8.792s	3 days ago	OK	Fail	Pass	Fail	Pass	Pass	Pass
tr-3ebc62...	{ "customer_name": "Global Retail", ...}	3.725s	3 days ago	OK	Pass	Pass	Fail	Pass	Pass	Pass
tr-830bbb...	{ "customer_name": "Acme Corp", "..."}	10.995s	3 days ago	OK	Fail	Fail	Fail	Pass	Pass	Pass
tr-bba430...	{ "customer_name": "Global Retail", ...}	4.372s	3 days ago	OK	Fail	Pass	Fail	Pass	Pass	Pass
tr-c8b2fcf...	{ "customer_name": "TechStart", "u..."}	3.534s	3 days ago	OK	Fail	Fail	Fail	Pass	Pass	Pass
tr-cc9ce3...	{ "customer_name": "Acme Corp", "..."}	6.143s	3 days ago	OK	Fail	Fail	Fail	Pass	Pass	Pass
tr-5456fc...	{ "customer_name": "Acme Corp", "..."}	5.554s	3 days ago	OK	Fail	Pass	Fail	Pass	Pass	Pass
tr-bc3a88...	{ "customer_name": "Acme Corp", "..."}	5.359s	3 days ago	OK	Fail	Pass	Fail	Pass	Pass	Pass

*MLFlow verwaltet den Machine-Learning-Lifecycle, einschließlich Experimente, Reproduzierbarkeit, Deployment und ein zentrales Model-Registry*

## Ergebnisse:

- Vollständig operatives Produktionssystem deployed auf der Fertigungsfläche
- Operative Verfahren und Wartungsprotokolle
- Continuous-Improvement-Prozess und Model-Monitoring-Framework
- Finaler Projektbericht mit Performance-Validierungsergebnissen

# Roadmap



## Arbeitspakete

Arbeitspaket	Dauer
Literaturrecherche	2 Tage
Data Loading & Cleaning Setup	2 Tage
Sampling-Analyse & Datenqualitätsbericht	2 Tage
Datentrennung & Failure Mapping	1.5 Tage
RUL Label-Erstellung	1 Tage
Feature-Trend-Visualisierung	2 Tage
Vergleich vor/nach Austausch	2 Tage
Signal-Korrelationsstudie	1.5 Tage
Feature-Stabilitäts- & Degradationsprüfung	1.5 Tage
Predictive Signal-Bewertung	1.5 Tage
Rolling Window Feature Engineering	2 Tage
Frequency-Domain Feature Engineering	2 Tage
Feature Aggregation & Normalization	1.5 Tage
Analyse und Lösungs-/Paper-Auswahl	2 Tage
Baseline RUL Modeling basierend auf CNC Papers	5 Tage
Validation Pipeline-Implementierung	2 Tage
Model Validation & Metriken	2 Tage

Ergebnisse, Dokumentation, Präsentation	2 Tage
High Resolution Data Streaming	8 Tage
Machbarkeit: Monitor Data Acquisition	3 Tage
Historischer Datenzugang einrichten	2.5 Tage
Real-time Data Ingestion	4 Tage
Data Validation Pipeline	3 Tage
Infrastruktur Setup: Environment	4 Tage
Infrastruktur Setup: Database Deployment	3 Tage
Infrastruktur Setup: Backend API-Entwicklung	9 Tage
Infrastruktur Setup: Network/VPN-Konfiguration	2 Tage
Infrastruktur Setup: Monitoring & Logging	2 Tage
Dashboard-Entwicklung: Infrastructure	1 Tage
Dashboard-Entwicklung: Historische Trend-Ansichten	2 Tage
Dashboard-Entwicklung: Alerting	2 Tage
Pilotensystem & Validation: End-to-end Testing	3 Tage
Pilotensystem & Validation: Performance Validation	3 Tage
Pilotensystem & Validation: Dokumentation	3 Tage
Rollout: ML Model-Iteration	6 Tage
Rollout: Alert-Schwellenwerte anpassen	1.5 Tage
Rollout: Model Performance Monitoring	1 Tage

Rollout: Production Monitoring konfigurieren	3 Tage
Meetings & Projektmanagement	13 Tage
<b>Gesamtdauer</b>	<b>123.5 Tage</b>

## Rollen und Kosten

Rolle	Level	Tagessatz	Tage	Gesamtkosten
ML Engineer	Technology Specialist IV	1,120.00 €	48.00 Tage	53,760.00 €
Senior Software Engineer	Technology Specialist IV	1,120.00 €	72.50 Tage	81,200.00 €
Project Owner	Project Management IV	1,344.00 €	3.00 Tage	4,032.00 €
<b>Gesamtkosten Entwicklung</b>				<b>138,992.00 €</b>
Reisekosten				12,186.97 €
Fixkosten				2,500.00 €
<b>Gesamtkosten Netto</b>				<b>153,678.97 €</b>
Steuer (19%)				29,199.00 €
<b>Gesamtkosten Brutto</b>				<b>182,877.98 €</b>

## Kosten für Machbarkeitsstudie

Rolle	Level	Tagessatz	Tage	Gesamtkosten
ML Engineer	Technology Specialist IV	1,120.00 €	15.50 Tage	17,360.00 €
Senior Software Engineer	Technology Specialist IV	1,120.00 €	4.00 Tage	4,480.00 €
Project Owner	Project Management IV	1,344.00 €	3.00 Tage	4,032.00 €
<b>Gesamtkosten Entwicklung</b>				<b>25,872.00 €</b>
Reisekosten				2,530.80 €
Fixkosten				500.00 €
<b>Gesamtkosten Netto</b>				<b>28,902.80 €</b>
Steuer (19%)				5,491.53 €
<b>Gesamtkosten Brutto</b>				<b>34,394.33 €</b>

## Rate Card

Es gilt die Rate Card aus dem Rahmenvertrag, Stand 2025:

Bereich	Titel	Level	Stundensatz	Tagessatz
Technology Specialist	Senior Lead Tech Specialist	Technology Specialist VI	180.00 €	1,440.00 €
	Lead Tech Specialist	Technology Specialist V	161.00 €	1,288.00 €
	Senior Tech Specialist	Technology Specialist IV	140.00 €	1,120.00 €
	Tech Specialist	Technology Specialist III	126.00 €	1,008.00 €
	Associate Tech Specialist	Technology Specialist III	112.00 €	896.00 €
	Developer	Technology Specialist I	84.00 €	672.00 €
Project Management	Partner	Project Management VI	230.00 €	1,840.00 €
	Senior Technical Executive	Project Management V	187.00 €	1,496.00 €
	Technical Executive	Project Management IV	168.00 €	1,344.00 €
	Senior Project Owner	Project Management III	149.00 €	1,192.00 €
	Project Owner	Project Management II	133.00 €	1,064.00 €

Die oben skizzierten Projektrollen stellen ein Referenzteam dar. Sollte es bei der Besetzung der Projektrollen zu Abweichungen kommen, gilt folgende Rate Card. Das Projektvolumen bleibt unberührt.

## **Rechtlicher Rahmen**

Es gelten die rechtlichen Bedingungen aus dem gemeinsamen Rahmenvertrag sowie die Tagesraten aus der aktuell vereinbarten Rate Card.

# Unterschrift

**AB-250926.4-51612.12**

Wir bitten darum den unterzeichneten Vertrag oder Ihre Bestellung an [bestellung@motius.de](mailto:bestellung@motius.de) zu versenden.

Dieses Angebot gilt bis 2025-10-26

SEW-EURODRIVE GmbH & Co KG

Auftraggeber

Motius GmbH

Auftragnehmer

---

Zeichnungsberechtigter

---

Ort, Datum

---

Zeichnungsberechtigter

---

Ort, Datum

---

Unterschrift

---

Unterschrift