



**Vorhabensbeschreibung
für das Forschungsvorhaben**

Predictive and Prescriptive Process Monitoring for Industrial Production Processes (3PMIPP)
(Prädiktives und Präskriptives Process Monitoring für Produktionsprozesse in der Industrie)

im Rahmen des Software Campus

15. Februar 2023

Antragssteller: (Projektrahmen-Vorhaben)	Friedrich-Alexander-Universität Erlangen-Nürnberg
Projektleiter: (Mikroprojekt)	Annina Ließmann Friedrich-Alexander-Universität Erlangen-Nürnberg Lehrstuhl für Digital Industrial Service Systems Fürther Straße 248, 90429 Nürnberg annina.liessmann@fau.de +49 (0) 911 5302-96 485
Akademischer Betreuer:	Prof. Dr. Martin Matzner Friedrich-Alexander-Universität Erlangen-Nürnberg Lehrstuhl für Digital Industrial Service Systems Fürther Straße 248, 90429 Nürnberg martin.matzner@fau.de +49 (0) 911 5302-96 480
Praxispartner Betreuer:	Dr. Christian Schriever Carl Zeiss SMT GmbH Rudolf-Eber-Straße 2, 73447 Oberkochen christian.schriever@zeiss.com
Beginn des Mikroprojekts:	01.04.2023
Laufzeit des Mikroprojekts:	2 Jahre

Inhaltsverzeichnis

1	Aufgabenstellung und Motivation	3
1.1	Schwerpunkte und Ziele	4
1.2	Wissenschaftliche und / oder technische Ziele des Vorhabens	5
1.3	Bezug des Vorhabens zu förderpolitischen Zielen / Förderprogramm	5
2	Stand der Wissenschaft und Technik	6
2.1	Process Monitoring (deskriptiv und diagnostisch)	6
2.2	Predictive Process Monitoring	7
2.3	Prescriptive Process Monitoring	7
3	Partner und bisherige Arbeiten	10
3.1	Universität/Forschungseinrichtung	10
3.2	Bisherige Arbeiten	11
3.3	Unternehmen (ungeförderter Industriepartner)	12
3.4	Beziehung Universität - Unternehmen	12
4	Ausführliche Beschreibung des Arbeitsplans	13
4.1	Arbeitspakete	13
4.1.1	AP-1 - Ist-Analyse (Monat 1–3)	13
4.1.2	AP-2 - Literatur Recherche (Monat 1–3)	14
4.1.3	AP-3 - Erarbeitung des Gesamtkonzeptes (Monat 4–7)	14
4.1.4	AP-4 - Deskriptives und diagnostisches Process Monitoring (Monat 8–12)	15
4.1.5	AP-5 - Vorausschauendes Process Monitoring (Monat 12–17)	15
4.1.6	AP-6 - Empfehlungen zur Prozessoptimierung (Monat 17–22)	16
4.1.7	AP-7 - Evaluierung des Gesamtkonzeptes (Monat 23–24)	16
4.1.8	AP-8 - Projektmanagement (Monat 1–24)	17
4.2	Zeitplanung und Meilensteine	18
4.2.1	Zeitliche Aufteilung der Meilensteine	18
4.2.2	Meilensteine	18
4.2.3	Zuordnung von Personal zu Arbeitspaketen	19
4.3	Finanzplanung	19
4.3.1	Wissenschaftlicher Mitarbeiter	20
4.3.2	Studentische Hilfskraft	20
4.3.3	Dienstreisen	20
4.3.4	Sonstiges	21
5	Verwertungsplan	22
5.1	Wirtschaftliche Erfolgsaussichten	22
5.2	Wissenschaftlich-technische Erfolgsaussichten	22
5.3	Wissenschaftliche und wirtschaftliche Anschlussfähigkeit	22
6	Anhang	23
6.1	BahnCard 50	23
6.2	Overleaf	23
6.3	Mobile Workstation und Dock	24

1 Aufgabenstellung und Motivation

Die Industrie trug in Deutschland 2021 rund 30% zum Bruttoinlandsprodukt in Deutschland bei. Damit ist Deutschland im europäischen Vergleich deutlich stärker von der industriellen Produktion abhängig als beispielsweise ähnlich große europäische Volkswirtschaften, wie etwa Frankreich oder Großbritannien¹. Das stellt Deutschland aber auch vor große Herausforderungen. Dazu gehören langfristig unter anderem die Dekarbonisierung, der demografische Wandel und die De-Globalisierung². Um diese Herausforderungen im industriellen Sektor adressieren zu können, müssen industrielle Prozesse digitalisiert werden. Dies führte in den letzten Jahren vermehrt zu Initiativen rund um Industrie 4.0. Laut dem Digitalverband Bitkom kann die digitale Industrie 65 Millionen Tonnen CO₂ bis 2030 einsparen. Dazu tragen vor allem die Automatisierung der Produktion sowie der Einsatz von Technologien wie dem digitalen Zwilling (Digital Twin) bei, indem manuelle Eingriffe und Materialeinsatz reduziert und Prozesse optimiert werden [1].

Das Bundesministerium für Bildung und Forschung (BMBF) beschreibt 2016 die Vision von Industrie 4.0 wie folgt: *“Maschinen, die miteinander kommunizieren, sich gegenseitig über Fehler im Fertigungsprozess informieren, knappe Materialbestände identifizieren und nachbestellen – das ist eine intelligente Fabrik”*.³

In einer Umfrage von Bitkom geben 90% der Befragten Industrieunternehmen an, Anwendungen für Industrie 4.0 in 2022 zu nutzen oder deren Einsatz zu planen. In Produktionsprozessen, die mit Hilfe von Anwendungen aus der Industrie 4.0 digitalisiert worden sind, entstehen unter anderem große Mengen an Daten während der operativen Abwicklung der Prozesse. Die Analyse dieser Daten hat entsprechend großes Potential, weitere Optimierungsmöglichkeiten aufzuzeigen.

Für die Analyse von Prozessdaten gewinnt *Process Mining* in der Wissenschaft und auch bereits in der Wirtschaft immer mehr an Bedeutung. Mit Process Mining wird versucht, ein tiefgreifendes Verständnis von Prozessen, z. B. in Bezug auf Schwachstellen, zu erlangen. Process Mining, oft als die Verbindung von Process Science und Data Science beschrieben, ermöglicht es, basierend auf Daten aus Informationssystemen („data-driven“) Geschäftsprozesse („process centric“) zu erkennen, auf Konformität zu überprüfen und zu analysieren, um diese Prozesse zu verbessern [23, S.25f]. Hierfür werden Prozessdaten in der Form eines Event Logs verwendet, die während des Durchlaufens eines digitalisierten Prozesses zu den einzelnen Prozessschritten in Informationssystemen gesammelt werden.

In einem Produktionsprozess, der durch Anwendungen aus der Industrie 4.0 digitalisiert abläuft, kann Process Mining eine Möglichkeit zur Prozessüberwachung (Process Monitoring) des gesamten Produktionsprozesses bieten. Die oftmals schwierig nachvollziehbare Kommunikation zwischen Maschinen innerhalb des Industrial Internet of Things (IIoT) kann mit Hilfe von Process Mining Methoden sichtbar gemacht werden und im Kontext des Produktionsprozesses analysiert werden. Die Aufbereitung dieser Daten aus Prozessperspektive kann unter Umständen wichtige Anhaltspunkte zur Optimierung des Produktionsprozesses beinhalten.

Im Rahmen von Process Monitoring werden noch laufende Produktionsprozesse analysiert, um eventuelle Abweichungen vom Soll-Prozess schnellstmöglich zu erkennen und Gegenmaßnahmen einzuleiten. Ähnlich wie bei den von Gartner beschriebenen Datenanalyse Typen (siehe Abbildung 1) sind die Kernfragen für Process Monitoring *deskriptiver* (“Was ist passiert?“) und *diagnostischer* (“Warum ist etwas passiert?“) Natur. Jedoch haben sich Process Mining Methoden auch weiterentwickelt. In den letzten Jahren sind vor allem *prädiktive* Process Monitoring Ansätze in den Fokus gerückt, um die Frage “Wie wahrscheinlich ist es, dass etwas passiert?“ zu beantworten. Noch weniger erforscht sind bisher Ansätze für *präskriptive* Process Monitoring, indem man sich mit der Frage beschäftigt “Was sollte getan werden, damit etwas (nicht) passiert?“. Die Beantwortung dieser Fragen für einen Produktionsprozess kann dementsprechend maßgeblich zu dessen Optimierung beitragen.

¹<https://de.statista.com/statistik/daten/studie/37088/umfrage/anteile-der-wirtschaftssektoren-am-bip-ausgewaehlter-laender/> (aufgerufen am 16. Januar 2023)

²<https://www.iwkoeln.de/presse/pressemitteilungen/vera-demary-juergen-matthes-axel-pluennecke-thilo-schaefer-das-sind-die-groesstenherausforderungen.html> (aufgerufen am 16. Januar 2023)

³<https://www.bmbf.de/bmbf/de/forschung/digitale-wirtschaft-und-gesellschaft/industrie-4-0/industrie-4-0.html> (aufgerufen am 16. Januar 2023)

An dieser Stelle knüpft das Forschungsprojekt *Predictive and Prescriptive Process Monitoring for Industrial Production Processes (3PMIPP)* an. Die vorliegende Vorhabensbeschreibung gliedert sich in fünf Abschnitte. So sollen zunächst in Kapitel 1 die inhaltlichen Ziele und Schwerpunkte, die wissenschaftlichen und technischen Ziele, sowie der Bezug zu den förderpolitischen Zielen definiert werden. In Kapitel 2 wird der aktuelle Stand von Wissenschaft und Technik hinsichtlich Process Monitoring Ansätzen beschrieben. Anschließend wird in Kapitel 3 auf die beteiligten Partner, also die Friedrich-Alexander-Universität Erlangen-Nürnberg, insbesondere den Lehrstuhl für Digital Industrial Service Systems, sowie die Firma Carl Zeiss Semiconductor Manufacturing Technology (Zeiss SMT) eingegangen. Dabei soll auch die Beziehung zwischen Universität und Unternehmen geschildert werden. In Kapitel 4 wird der Arbeitsplan genauer beschrieben. Dieses Kapitel gliedert sich in die Beschreibung der acht definierten Arbeitspakete, die Zeitplanung, die Meilensteine sowie in die Finanzplanung. Im letzten Kapitel 5 wird auf die wirtschaftlichen und wissenschaftlich-technischen Erfolgsaussichten eingegangen und die Anschlussfähigkeit des Projektes beschrieben.

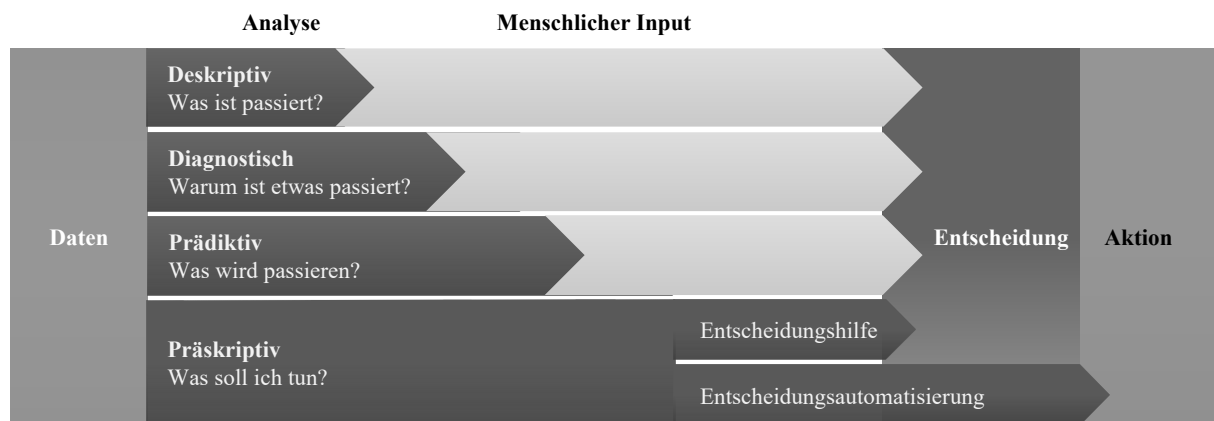


Abbildung 1: Vier Typen der Datenanalyse [nach 9]

1.1 Schwerpunkte und Ziele

Wie bereits im vorhergehenden Kapitel 1 beschrieben, ist das übergeordnete Ziel des vorliegenden Forschungsvorhabens, Methoden aus dem Process Monitoring spezifisch für das Produktionsumfeld zu entwickeln, um Produktionsprozesse zu optimieren. Gerade im Bereich Process Monitoring werden Methoden entwickelt und mit simulierten oder veröffentlichten Unternehmensdaten evaluiert. Diese verfügbaren Datensätze besitzen wenig zusätzliche Informationen zum Kontext, in dem Prozessschritte ausgeführt werden. Zudem haben die veröffentlichten Datensätze einen klaren Fokus auf unterstützende Prozesse im Unternehmen, wie beispielsweise ein IT Support Prozess. Mit diesem Projekt soll das Anwendungsfeld von Process Monitoring zur Optimierung eines Kernprozesses in der Produktion erschlossen werden. Dabei werden folgende drei Schwerpunkte gesetzt:

1. **Deskriptives / Diagnostische Process Monitoring**
2. **Prädiktives Process Monitoring**
3. **Präskeptives Process Monitoring**

Für jeden Schwerpunkt sollen der Stand der Technik und das Einsatzpotenzial eruiert, mögliche Anwendungsfälle identifiziert, umgesetzt und evaluiert werden.

1.2 Wissenschaftliche und / oder technische Ziele des Vorhabens

Das Forschungsprojekt *Predictive and Prescriptive Process Monitoring for Industrial Production Processes (3PMIPP)* entwickelt ein Gesamtkonzept zur Anwendung von Process Monitoring Methoden in der Produktion. Auf Basis dieser Ziele und vor dem thematischen Hintergrund wurden für das Forschungsprojekt 3PMIPP folgende Forschungsfragen (Research Questions, RQs) definiert:

- **RQ-1** Welche Prozessoptimierungsmethoden innerhalb von Process Mining aus der Forschung haben Potenzial zur Anwendung in der Fertigungsindustrie?
- **RQ-2** Lässt sich Predictive Process Monitoring in der Produktion anwenden und falls ja, unter welchen Voraussetzungen?
- **RQ-3** Lässt sich Prescriptive Process Monitoring in der Produktion anwenden und falls ja, unter welchen Voraussetzungen?
- **RQ-4** Wie kann ein Gesamtkonzept zur Umsetzung von Process Monitoring zur Optimierung von Produktionsprozessen aussehen?

1.3 Bezug des Vorhabens zu förderpolitischen Zielen / Förderprogramm

Das Projekt ist Teil des Software Campus Programms, welches in die Aktivitäten der EIT ICT Labs eingebettet ist. Ziel des Programms ist die Ausbildung der zukünftigen IT-Führungskräfte am Standort Deutschland sowie die Förderung von innovativen Forschungsprojekten. Diese Fördermaßnahme ist Teil der Hightech-Strategie der Bundesregierung. Konkret nimmt das Vorhaben Bezug zum Bereich *Wirtschaft und Arbeit 4.0* im *Handlungsfeld I* der Hightech-Strategie 2025 ein. Die datenbasierte Optimierung von Produktionsprozessen mit Hilfe von Process Monitoring trägt entscheidend dazu bei, Produktionstechnologien modern, effizient und verträglich zu gestalten. Zudem bezieht sich das Vorhaben mit anwendungsnahen Prototypen für prädiktives und präskriptives Process Monitoring, welche auf Machine Learning basieren, auch auf die Mission “Künstliche Intelligenz in die Anwendung bringen” (*Handlungsfeld II*).

Das Projekt lebt von einer praxisnahen Umsetzung mit direktem Problembezug. Daher bietet der Software Campus als Plattform für die Zusammenarbeit von Forschungs- und Industriepartnern eine ideale Möglichkeit, die Idee zielgerichtet und problemorientiert in Kooperation mit Zeiss SMT zu verwirklichen. Das Mentoring hilft zudem für weitere Themen zu sensibilisieren, zum Beispiel wie man die entwickelten Anwendungen sinnvoll in einer Organisation einführt. Die Trainings bilden einen weiteren Baustein des Programms, welche wichtige Kompetenzen in den Kernbereichen Methoden, Sozial- und Selbstkompetenz und Führung vermitteln, um die Projektidee erfolgreich umzusetzen.

2 Stand der Wissenschaft und Technik

In den drei folgenden Kapiteln wird der aktuelle Stand der Wissenschaft und Technik für die in diesem Vorhaben relevanten Bereiche des Process Monitorings vorgestellt.

2.1 Process Monitoring (deskriptiv und diagnostisch)

Process Monitoring ist eine Phase des Business Process Management (BPM) Lifecycles. Der BPM Lifecycle gibt einen Überblick über Konzepte, Methoden, Techniken und Werkzeuge, aus denen sich die BPM-Disziplin zusammensetzt [8, S.17-27]. Dazu gehören die Identifikation eines Prozesses, dessen Ermittlung in Form eines Ist-Prozessmodells (Discovery), die Prozessanalyse und Umgestaltung, die Implementierung des umgestalteten Soll-Prozessmodells sowie das anschließende Monitoring des verbesserten Prozesses. Process Monitoring beschäftigt sich damit, laufende Prozesse basierend auf ihre Performance zu analysieren. Engpässe, wiederkehrende Fehler oder Abweichungen vom beabsichtigten Verhalten können identifiziert und Korrekturmaßnahmen eingeleitet werden [8, S.23f]. Der Fokus liegt auf der Analyse der Vergangenheit. Zentrale Fragen sind “Was ist passiert?” (deskriptiv) und “Warum ist etwas passiert?” (diagnostisch). Process Mining bietet dafür passende, datengetriebene Methoden.

Der Event Log bildet die Grundlage für Process Mining. Ein Event Log beinhaltet Daten, die aus mitunter verschiedenen Informationssystemen im Unternehmen während der Ausführung eines Prozesses gesammelt werden. Er besteht aus Case IDs, die einzelne Prozessdurchläufe (sogenannte Cases) charakterisieren, und Events, die Informationen zu den einzelnen Prozessschritten beinhalten, zum Beispiel Attribute wie Aktivität, Zeit, Mitarbeiter oder Kosten. Wichtig ist außerdem die zeitliche Sortierung der Events innerhalb eines Cases, zum Beispiel mit Hilfe eines Zeitstempels [23, S.128-137].

Die ursprünglichen drei Teilgebiete von Process Mining sind Process Discovery, Conformance Checking und Process Enhancement [23, S.32ff]. *Process Discovery* ist die Rekonstruktion von Prozessmodellen aus Event Logs. Konträr zu anderen Methoden aus dem BPM, wie Dokumenten Analyse, Beobachtungen, Interviews oder Workshops werden Prozessmodelle mit Hilfe von Algorithmen und Daten aus Informationssystemen im Unternehmen von ausgeführten Prozessen generiert [8, S.165-176]. Damit lässt sich das tatsächlich gelebte Ist-Prozessmodell visualisieren. *Conformance Checking* führt einen Abgleich zwischen dem Ideal und dem tatsächlich abgelaufenen Prozess durch. Neben Methoden, die als Ideal ein gesamtes Prozessmodell verwenden, gibt es auch deklarative Methoden, die spezifische Einschränkungen (constraints) definieren [23, S.243-267]. *Process Enhancement* erweitert das Prozessmodell um zusätzliche Informationen aus dem Event Log oder verändert dieses zu einem optimierten Prozessmodell [23, S.33f].

Process Mining wird bisher hauptsächlich zur Optimierung von Standardprozessen wie Order-to-Cash (O2C) oder Purchase-to-Pay (P2P) verwendet. Die Anwendung von Process Mining innerhalb des Produktionskontexts ist nicht weit verbreitet [24]. Gründe hierfür könnten eigene, zusätzliche Herausforderungen im Produktionsumfeld sein. Dazu gehören beispielsweise die folgenden Punkte:

- **Granularität und Abstraktion** In einem Produktionsprozess werden Daten auf verschiedenen Granularitätsebenen gesammelt, zum Beispiel Arbeitsschritte, Machinendaten, Messdaten oder Umweltdaten. IIoT Sensordaten können sich auf ein Event, mehrere Events (komplexe N:M Relationen möglich) oder auf den gesamten Prozess beziehen [12]. Diese Abstraktion von IIoT Daten auf Events ist nicht trivial und erfordert mitunter spezielle Methoden, wie Clustering oder Prozesswissen [4].
- **Datenqualität** Ausfälle und inkorrekte Messungen von Sensoren reduzieren die Datenqualität. Um Sensordaten für Process Mining nutzbar zu machen, ist eine komplexe Vorverarbeitung und unter Umständen Expertenwissen notwendig [4; 12; 14, S.67f].
- **Bereitstellung von Daten** Um schnell auf Veränderungen reagieren zu können, müssen Daten für “near-real-time” Analysen bereitgestellt werden [14, S.67f].
- **Weitere produktionsspezifische Aspekte** Neben Daten zur Herstellung der Produkte sollten auch weitere produktionsspezifische Aspekte in Analysen berücksichtigt werden, zum Beispiel Schichtbetrieb, Maschinenwartungsarbeiten oder Testläufe für die Produktion von neuen Produkten [14, S.67f].

Für diese Herausforderungen existieren zum Teil individuelle Lösungsvorschläge und Konzepte [zum Beispiel 10; 4], eine ganzheitliche Betrachtung der Anwendung von Process Mining in der Produktion fehlt jedoch bisher. Eine Möglichkeit wären Digital Shadows, eine leichtgewichtige Variante von Digital Twins [17]. Im Process Mining Kontext könnten Digital Shadows sowohl Prozessmodelle als auch Event Log Daten beinhalten, um Produktionsprozesse zu analysieren [24].

2.2 Predictive Process Monitoring

In den letzten Jahren hat Predictive Process Monitoring sich als Teilgebiet von Process Mining etabliert. Ziel ist es, den zukünftigen Zustand, das Ergebnis oder Eigenschaften einer laufenden Prozessinstanz vorherzusagen. Die zentrale Frage ist “Wie wahrscheinlich ist es, dass etwas passiert?”, zum Beispiel die nächste Aktivität, verbleibende Zeit, Arbeitsbelastung oder Kosten [6]. Di Francescomarino und Ghidini [5] schlagen eine Unterteilung in zwei Gruppe vor: 1) Modell-basierte Predictive Process Monitoring Ansätze und 2) Ansätze, welche statistische Methoden und Machine Learning verwenden.

Modell-basierte Ansätze, zum Beispiel Annotated Transition Systems, verwenden ein explizites Prozessmodell, welches während der Trainingsphase, falls noch nicht vorhanden, erstellt und mit Daten entsprechend angereichert wird. Zu jeder Aktivität innerhalb des Prozesses kann beispielsweise die verbleibende Zeit bis zur Vollendung des Cases als Zustand gespeichert werden. In der Anwendungsphase, für die Vorhersage der restlichen Zeit eines noch nicht beendeten Cases, wird dieser auf das annotierte Prozessmodell abgebildet. Eine definierte Vorhersagefunktion gibt dann basierend auf dem Zustand des annotierten Modells eine Vorhersage der verbleibenden Zeit bis der Case abgeschlossen ist [5].

Die zweite Gruppe besteht aus Ansätzen, die Machine Learning Methoden zur Erstellung eines Vorhersagemodells verwenden. Di Francescomarino und Ghidini [5] berücksichtigen in dieser Gruppe nur Methoden aus dem Supervised Machine Learning. Die spezifische Methode hängt dabei vom Datentyp des Vorhersageziels ab. Ist das Vorhersageziel das kategorische Ergebnis eines Cases eignen sich klassifikationsbasierte Ansätze (Classification) wie Decision Trees, Random Forests und Support Vector Machines. Bezieht sich das Ergebnis auf quantitative Metriken, wie zum Beispiel Durchlaufzeit oder Kosten, werden hauptsächlich regressionsbasierte Ansätze (z.B. Regression Trees, Random Forest, XGBoost) verwendet. Ist das Vorhersageziel eines der Attribute des nächsten Events (z.B. welche Aktivität folgt oder wann die nächste Aktivität ausgeführt wird) haben sich besonders Verfahren aus dem Deep Learning bewährt. Vor allem Long Short Term Memory (LSTM) Architekturen sind für längere Sequenzen geeignet und zeigen vielversprechende Ergebnisse in der Vorhersage des nächsten Events [5].

Machine Learning basierte Ansätze haben ebenso wie Modell-basierte Ansätze eine Trainings- und eine Anwendungsphase. In Márquez-Chamorro et al.’s [20] Beschreibung einer generellen Methode für Predictive Monitoring wird zwischen offline und online Phasen unterschieden (siehe Abbildung 2). Die Methode benötigt als Input den Event Log mit historischen Prozessdaten. Einige Methoden verwenden zusätzlich noch ein Prozessmodell und/oder zusätzliche, zum Prozess externe Daten, wie zum Beispiel Informationen zum Wetter. Um mit den Daten ein Vorhersagemodell zu trainieren, müssen diese vorher einen Encoding Schritt durchlaufen [siehe 16]. Zudem wird das Vorhersagemodell evaluiert, bevor es in der online Phase für Vorhersagen zu noch laufenden Cases verwendet werden kann.

2.3 Prescriptive Process Monitoring

Predictive Process Monitoring Methoden sagen die Wahrscheinlichkeit vorher, dass ein bestimmtes Ergebnis eintritt, was die nächste Aktivität ist, oder wie lange der Prozess dauern wird. Jedoch sind diese Methoden auf die Vorhersage beschränkt. Mitarbeitende müssen entscheiden, ob es sich lohnt, den laufenden Case zu verändern und falls ja, wie dieser verändert werden sollte, um eine Prozesskennzahl zu verbessern [22]. Hier knüpft ein neues Feld, Prescriptive Process Monitoring, an.

Während prädiktive Methoden, wie Predictive Process Monitoring, darauf abzielen, (nicht deterministische) Abhängigkeiten zwischen Instanzen X (zum Beispiel Cases) und zugehörigen Ergebnissen Y (zum Beispiel die Qualität eines Produkts am Ende des Produktionsprozesses) zu erfassen, versuchen präskriptive Methoden eine Entscheidung Y basierend auf einer Situation X zu treffen. In prädiktiven Methoden existiert die Qualität eines Produkts unabhängig von der jeweiligen Vorhersage. Jede Instanz X hat eine Grundwahrheit (ground truth) in Form von Y . Diese Grundwahrheit und somit das Lernziel

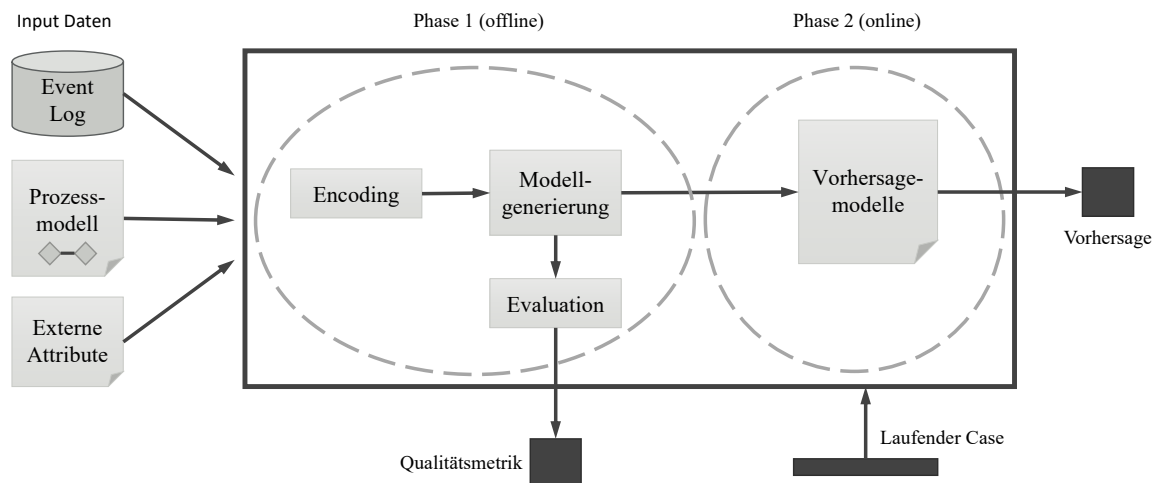


Abbildung 2: Generelle Methode für Predictive Monitoring nach Márquez-Chamorro et al. [20]

eines Machine Learning Algorithmus kann bei präskriptiven Methoden fehlen. Hüllermeier [11] ist der Meinung, dass auch der Begriff der „besten Entscheidung“ kein guter Ersatz für eine Grundwahrheit ist, da diese nur schwer in der Praxis bestimmt werden kann. Hierfür müssten gegebenenfalls unendlich viele mögliche Szenarien (counterfactuals) evaluiert werden, um die „beste“ Entscheidung für eine Intervention zu finden. Das geben historische Daten in vielen Fällen nicht her. Eine Möglichkeit, sich der „besten“ Entscheidung anzunähern bietet Causal Machine Learning. Kausalität beschreibt den Einfluss eines Zustands (cause) auf einen anderen Zustand (effect). Kellner [13] beschreibt zwei verschiedene Perspektiven auf Causal Machine Learning: 1) Machine Learning Methoden zur Verbesserung der kausalen Inferenz (causal inference, Prozess der Bestimmung der Wirkung) und 2) Kausalität zur Verbesserung der Machine Learning Methoden.

Die bisherige, analytische Aufgabe des Lernens von Zusammenhängen zwischen Instanzen X und Ergebnissen Y (prädiktive Methoden) verändert sich demnach zu einer synthetischen Aufgabe der Konstruktion eines Entscheidungsmodells (präskriptive Methoden). Der Fokus liegt dabei auf „praktischen“ Entscheidungsmodellen, welche mehrere Kriterien wie Wert, Komplexität, Kosten und Fairness gleichermaßen betrachten [11].

Den Grundgedanken von präskriptiven Methoden greift Prescriptive Process Monitoring auf. Hier kann man bisher zwischen zwei Teilgruppen unterscheiden: Methoden, die Entscheidungen geben um 1) ein unerwünschtes Ergebnis zu verhindern oder abzumildern oder 2) eine Kennzahl zu optimieren [5].

Teinemaa et al. [22] stellen ein Alarm-System vor, welche eine prädiktive Methode zur Vorhersage eines Prozessergebnisses mit einem Kostenmodell erweitert. In diesem Kostenmodell werden Kosten der Durchführung einer Intervention, Kosten keiner Intervention (Kosten verursacht durch ein unerwünschtes Prozessergebnis), zusätzliche Kosten einer nicht notwendigen Intervention und vermiedene Kosten durch eine Intervention berücksichtigt. In der Trainingsphase wird ein Schwellwert optimiert, um die Gesamtkosten zu minimieren. Bei der Vorhersage der Wahrscheinlichkeit eines negativen Prozessergebnisses für eine noch laufende Prozessinstanz dient der Schwellwert zur Entscheidung, einen Alarm für eine Intervention zu geben. Für die Vorhersage wurden Random Forests und Gradient Boosted Trees verwendet.

Metzger et al. [19] verwendet ein ähnliches Kostenmodell, um den richtigen Zeitpunkt einer Vorhersage, und der daraus resultierenden Interventionsentscheidung, zu bestimmen. Je früher man die Information zu einem möglichen unerwünschten Prozessergebnis hat, desto mehr Zeit hat man für Interventionen. Jedoch leidet die Treffergenauigkeit (accuracy), je früher im Prozess eine Vorhersage getroffen wird. Um den frühesten Zeitpunkt zu bestimmen, werden mehrere Recurrent Neural Networks (mit LSTM Architekturen) trainiert. Diese können Vorhersagen mit jeweiliger Zuverlässigkeitsschätzungen an beliebigen Zeitpunkten während der Prozessausführung erzeugen. Basierend auf der Zuverlässigkeitsschätzung wird der Zeitpunkt der Vorhersage bestimmt. Durch eine Mehrheitsentscheidung wird die finale Vorhersage bestimmt.

Die Methoden in Leoni et al. [15] und Weinzierl et al. [26] schlagen die nächste, prozesskonforme Aktivität für eine laufende Prozessinstanz vor, um eine Kennzahl zu optimieren. Leoni et al. [15] nutzen Predictive Process Monitoring (Decision Tree, Random Forest und Support Vector Machines), um eine Kennzahl für eine laufende Prozessinstanz vorherzusagen. Falls die Kennzahl unter einem Schwellwert liegt, wird jede mögliche, prozesskonforme Folgeaktivität simuliert und die Kennzahl wird erneut vorhergesagt. Die Folgeaktivität mit der voraussichtlich größten Kennzahlverbesserung wird vorgeschlagen. Weinzierl et al. [26]) verwenden zur Vorhersage der nächsten Aktivitäten und der Kennzahl einer laufenden Prozessinstanz ein Recurrent Neural Network (mit LSTM Architektur). Mit Hilfe einer Nearest-Neighbor Machine Learning Methode, trainiert mit historischen Event Log Daten, werden Alternative Prozesssequenzen generiert. Aus den resultierenden Kandidaten wird die Sequenz mit der voraussichtlich besten Kennzahl auf Konformität geprüft und anschließend als Folgeaktivität vorgeschlagen.

Die beschriebenen präskriptiven Methoden bauen alle auf Predictive Process Monitoring Methoden (Supervised Machine Learning) auf. Für konkrete Vorschläge, zum Beispiel um eine Kennzahl zu optimieren, werden alle möglichen (historisch bekannten) Prozesssequenzen simuliert. Dafür könnten sich wiederum die diesem Kapitel genannten Digital Shadows eignen. Im Machine Learning gibt es jedoch noch andere Ansätze, die sich für Prescriptive Process Monitoring eignen könnten. Neben Supervised Machine Learning kann Reinforcement Learning eine Alternative zum Vorschlagen der besten Folgeaktivität sein. Beim Reinforcement Learning hat jede Aktion einen Einfluss auf die Umwelt. Ein Agent lernt selbständig eine Strategie und wird durch Interaktion mit seiner Umwelt belohnt bzw. bestraft. Ein weiteres Teilgebiet im Machine Learning ist Causal Machine Learning. Wie bereits beschrieben geht es darum, kausale Zusammenhänge zu finden. Die gefundene Ursache (cause) eines ungewünschten Prozessergebnisses (effect) könnte im Prescriptive Process Monitoring als Anhaltspunkt für mögliche Prozessveränderungen/Interventionen verwendet werden. Zusammenfassend bietet das Forschungsfeld Machine Learning viele weitere Ansätze, Prescriptive Process Monitoring zu erweitern und zu verbessern. Innerhalb des Produktionsumfelds ist der Projektleiterin zum jetzigen Zeitpunkt keine bestehende Forschung für einen Prescriptive Process Monitoring Ansatz bekannt.

3 Partner und bisherige Arbeiten

Im Kontext der Software Campus Initiative gilt es eine IT-Idee in Form eines Forschungsprojekts umzusetzen. Beteiligt sind an diesem Forschungsprojekt die Friedrich-Alexander-Universität Erlangen Nürnberg (FAU) als Forschungspartner (vgl. Kapitel 3.1) und die Firma Zeiss SMT als Industriepartner (vgl. Kapitel 3.3). Auf relevante, bisherige Arbeiten wird in Kapitel 3.2 eingegangen. Die Beziehung zwischen der FAU und Zeiss SMT wird in Kapitel 3.4 beschrieben.

3.1 Universität/Forschungseinrichtung

Die FAU genießt aufgrund von zahlreichen Forschungsergebnissen aus verschiedenen Disziplinen bundesweites und internationales Ansehen. Die FAU ist eine der größten Universitäten Deutschlands mit derzeit rund 40.000 Studierenden, rund 630 Professorinnen und Professoren sowie knapp 6.000 Mitarbeitende⁴. Hervorragende Platzierungen in Forschungsrankings sowie beeindruckende nationale und internationale akademische Auszeichnungen belegen die Spitzenstellung der FAU, die zu den forschungsstärksten Universitäten in Deutschland gehört. Die Kooperation mit zahlreichen internationalen Spitzenuniversitäten bestätigt dies.

Das Institut für Wirtschaftsinformatik (WIN) ist eine gemeinsame Initiative der fünf Wirtschaftsinformatiklehrstühle sowie der vier Juniorprofessuren an der FAU am Standort Nürnberg des Fachbereichs für Wirtschafts- und Sozialwissenschaften. Das Institut arbeitet interdisziplinär mit den Informatiklehrstühlen der technischen Fakultät sowie der naturwissenschaftlichen Fakultät in Erlangen zusammen. Aufgrund dieser Kooperation besteht eine breite Aufstellung der FAU in Bezug auf Informatik, weshalb komplexe Projekte effizient und nachhaltig realisiert sowie verschiedenartige Themen im Rahmen der IT behandelt werden. In Deutschland gehört die FAU zu den Vorreitern in der Forschung der Wirtschaftsinformatik. Gründe hierfür sind beispielsweise die Innovationskraft der Universität und die Gründung des ersten deutschen Wirtschaftsinformatiklehrstuhls.

Die ungeforderte Projektleiterin ist wissenschaftliche Mitarbeiterin mit Promotionsziel am Lehrstuhl für Digital Industrial Service Systems von Prof. Dr. Matzner. Schwerpunktthema des Lehrstuhl ist die Verbesserung der Informationsverarbeitung und Entscheidungsfindung in Organisationen zum gegenseitigen Nutzen von Organisationen, Einzelpersonen und der Gesellschaft. Hierfür werden Techniken des Geschäftsprozessmanagements, der Informationsmodellierung als auch der Künstlichen Intelligenz genutzt. Die erzielten Ergebnisse leisten unmittelbare Beiträge zur Lösung betrieblicher Probleme und gesellschaftlicher Herausforderungen.

Die relevanten Forschungsbereiche des Lehrstuhls einschließlich Schwerpunktthemen sind nachfolgend aufgelistet:

- **Service Systems** Entwicklung von Theorien und Informationssysteme für Dienstleistungen, insb. Industrie 4.0 Dienstleistungen auf der Grundlage vernetzter, intelligenter Objekte und verteilter Informationssysteme (Cyber-physische Systeme (CPS), IIoT).
 - Digital Platforms
 - Ecosystems Analytics
 - Platform Ecosystems
 - Service Engineering
 - Service Management
 - Smart Service Systems

⁴<https://www.fau.de/fau/willkommen-an-der-fau/daten-und-fakten> (aufgerufen am 16. Januar 2023)

- **Decision Support** Entwicklung von Theorien, Modelle, Methoden und Softwarewerkzeugen um Entscheidungen von Interessenvertreter von Informationssystemen in Bezug auf betriebswirtschaftliche Leistungskennzahlen (z. B. Kosten) zu verbessern.
 - Decision Support Systems
 - Predictive Analytics
 - Prescriptive Analytics
 - Process Analytics
 - Visual Analytics
- **BPM** Entwicklung von Theorien, Modelle, Methoden und Softwarewerkzeugen für das Geschäftsprozessmanagement der Zukunft. Der Fokus liegt dabei auf der analytischen Anwendung des BPM.
 - Adaptive Case Management
 - Business Process Automation
 - Process Analytics
 - Process Mining
 - Predictive Business Process Monitoring
- **Information Management** Leisten von Beiträgen zur allgemeinen Organisations- und Informationssystemgestaltung.
 - Informationsmodellierung
 - Augmentation of Work
 - Automation von Entscheidungen
 - Algorithmische Unterstützung
 - Business Intelligence Architekturen

Darüber hinaus betreut der Lehrstuhl eine Vielzahl von Projekten, wodurch wesentliche Erfahrungen in den genannten Schwerpunktthemen gesammelt werden konnten. Hierbei kooperiert der Lehrstuhl mit nationalen als auch internationalen Forschungseinrichtungen (z. B. ERCIS (European Research Center for Information Systems)) sowie Unternehmen (z. B. Celonis).

3.2 Bisherige Arbeiten

Die ungeforderte Projektleiterin war vor Antritt ihrer Doktorandenstelle, Masterstudentin an der FAU. Während ihrer Studienzeit konnte sie in verschiedensten Werkstudentenstellen und Praktika Praxiserfahrung an der Schnittstelle von Business und IT. Zuletzt war sie bei Siemens tätig, wo sie im Rahmen ihrer Masterarbeit eine neue Methode zur Vorhersage von Kundenzufriedenheit bei IT Serviceleistungen entwickelt hat um Mitarbeitenden die Möglichkeit zu geben, frühzeitig einzugreifen. Durch die Kombination von Predictive Business Process Monitoring und Natural Language Processing Methoden konnte das Ergebnis des IT Service Prozesses mit Hilfe von Machine Learning vorhergesagt werden. Infolgedessen spezialisiert sich die ungeforderte Projektleiterin in ihrer Forschung nun auf die Entwicklung neuer technischer Artefakte im Bereich der Prozessvorhersage zur Entscheidungsunterstützung wie auch verwandter Fragestellungen, die sich mit der Einbettung dieser neuen Technologien in Informationssystemarchitekturen und organisatorische Umgebungen befassen.

Seit dem 01. Januar 2017 hat Prof. Dr. Matzner den Lehrstuhl für Digital Industrial Service Systems an der FAU inne. Vor seiner Zeit an der FAU arbeitete er als wissenschaftlicher Mitarbeiter an der Westfälische Wilhelms Universität in Münster am Lehrstuhl für Wirtschaftsinformatik und Informationsmanagement von Prof. Dr. Becker. Ein Teil dieses Lehrstuhls (einschließlich Prof. Dr. Matzner) hat ihren Forschungsschwerpunkt zum Teil auf das Gebiet der Process Analytics gelegt. Zu diesem Forschungsfeld wurden die nachfolgenden Publikationen veröffentlicht.

Breuker und Matzner [2] untersuchen zunächst einfache statistische Werkzeuge für die Mustererkennung in Sequenzen und integriert diese anschließend in den populären α -Algorithmus (für Prozessmodellextraktion basierend auf produzierten Ereignislogdaten eines Informationssystems). Schwegmann et al. [21] stellen eine prädikative, ereignisgetriebene Prozess Analytik Methode vor, die Aspekte aus den Feldern Business Activity Monitoring und Process Intelligence vereint und auf der Complex Event Processing Technologie (CEP) beruht. Matzner und Scholta [18] liefern einen Überblick über Process Mining Ansätze, um organisatorische Eigenschaften in Cyber-physischen Systemen zu erkennen. Breuker et al. [3] stellen eine prädiktive Modellierungstechnik (RegPFA) vor, die in Form von Wahrscheinlichkeiten darüber Auskunft gibt, wie sich eine laufende Prozessinstanz verhalten wird, basierend auf den Ereignissen die bisher beobachtet wurden. Weinzierl et al. [27] schlagen eine Machine Learning Methode mit LSTM Architektur vor, um die nächste Aktivität vorherzusagen. Drodts et al. [7] stellen ein Decision Support Tool vor, welches Vorschläge zur Datenvorverarbeitung, Machine Learning Algorithmus und Hyperparameter Konfiguration basierend auf einem Event Log macht und somit Forscher und Praktiker bei der Umsetzung von Predictive Process Monitoring unterstützt. Wie bereits in Kapitel 2.3) beschrieben haben Weinzierl et al. [26] eine präskriptive Process Monitoring Methode vorgestellt, welche die nächsten, besten Aktivitäten vorschlägt. Insbesondere die Entwicklung von neuartigen, erfolgreichen Ansätzen zur Prozessvorhersage untermauern die Expertise im Bereich des Predictive und Prescriptive Process Monitoring.

3.3 Unternehmen (ungeförderter Industriepartner)

Die Zeiss SMT GmbH entwickelt und fertigt Anlagen für die Produktion von Mikrochips. Zeiss SMT liefert Optiken für die Halbleiterlithographie, Photomaskensystemen sowie Prozesskontroll-Lösungen, welche Schlüsseltechnologien zur Fertigung feinsten Leiterbahnstrukturen auf Silizium-Wafern sind. Ein Großteil der Mikrochips weltweit wird mit Technologien von Zeiss SMT hergestellt. Zeiss SMT ist technologisch führend in der Fertigung von Systemen und Modulen zur Halbleiterfertigung.

Der Fortschritt der Computertechnologie beruht zum wesentlichen Teil auf der Weiterentwicklung der optischen Lithographie da sich mit jeder neuen Generation noch feinere Strukturen auf den Mikrochips abbilden lassen. Damit werden Schaltkreise kompakter und die Mikrochips jedes Jahr leistungsfähiger und energieeffizienter. Zeiss SMT treibt diese Entwicklung der Halbleiterfertigungstechnik von Beginn an voran. Das Unternehmen ermöglicht mit der einzigartigen Extreme Ultra Violet (EUV)-Lithographie eine Reihe weiterer Generationen von Mikrochips mit noch höherer Integration und Leistung. Zeiss SMT hat seinen Hauptsitz in der schwäbischen Stadt Oberkochen. Weitere Standorte befinden sich in Jena, Wetzlar, Roßdorf, Dublin (USA), Peabody (USA) und Bar Lev (Israel). Insgesamt sind etwa 6.000 Mitarbeitende an diesen sieben Standorten beschäftigt. Rund 30% aller Mitarbeiter sind im Bereich Forschung und Entwicklung eingesetzt.

Innerhalb der Zeiss SMT wurde Process Mining in ersten Anwendungsfällen, wie beispielsweise für den P2P Prozess, getestet. Bisher gibt es noch keine Anwendung von Process Mining in der Produktion.

3.4 Beziehung Universität - Unternehmen

Die Kooperation zwischen dem ungeförderter Industriepartner Zeiss SMT und dem Lehrstuhl für Digital Industrial Service Systems wird im Rahmen der Software Campus Initiative technischer (Projektumsetzung) sowie betriebswirtschaftlicher Natur (Projektmanagement) sein. Dazu gehört der regelmäßige Austausch über den Projektstatus, Vorgehensweise sowie Erfahrungsgewinne bei der Umsetzung der Projektidee. Die Expertise von Zeiss SMT in der Produktionsentwicklung und Fertigung sowie die Unterstützung durch Datenbereitstellung oder Simulation für Training und Evaluierung der Methoden trägt essentiell zum Erfolg des vorliegenden Vorhabens bei.

4 Ausführliche Beschreibung des Arbeitsplans

Zu Beginn wird in diesem Kapitel auf die geplanten Arbeitspakete (AP) eingegangen (vgl. Kapitel 4.1). Des Weiteren werden die Zeitplanung sowie die definierten Meilensteine beschrieben (vgl. Kapitel 4.2). Abschließend erfolgt eine ausführliche Erläuterung der Finanzplanung (vgl. Kapitel 4.3).

4.1 Arbeitspakete

Das Projekt gliedert sich in acht verschiedene AP, welche über die Laufzeit von zwei Jahren ab April 2023 bearbeitet werden. Aufgrund des agilen Charakters des Projektes orientieren sich die Arbeitspakete an der Process Mining Project Methodology (PM²) [25]. Diese bietet die Flexibilität, mehrere Iterationen zu durchlaufen und damit die Möglichkeit, Erkenntnisse aus vorherigen Iterationen mit einzubeziehen (siehe Abbildung 3). Für die Erstellung einer Methode zur Optimierung von Produktionsprozessen bedeutet das konkret, dass die Planung in AP-1 bis AP-3, die Iterationen in AP-4 bis AP-6 und die Verbesserungspotentiale in AP-7 zu finden sind. Über die gesamte Projektdauer ist zudem das AP Projektmanagement (AP-8) vorgesehen.

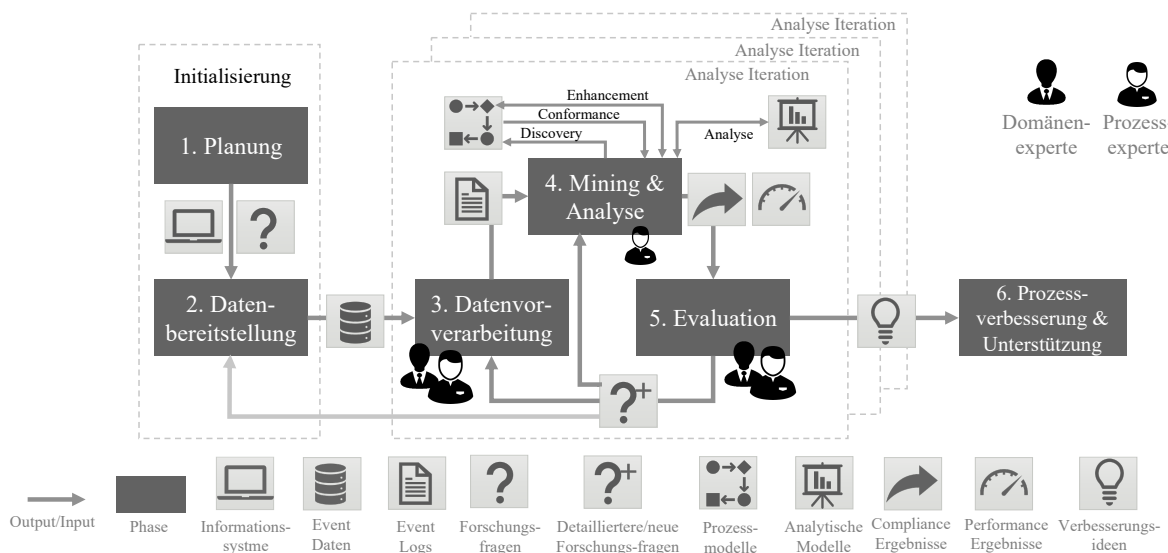


Abbildung 3: Process Mining Project Methodology (PM²) nach van Eck et al. [25]

Für die Bearbeitung der AP ist geplant, einen neuen wissenschaftlichen Mitarbeiter (50%) sowie eine studentische Hilfskraft für 24 Monate (entspricht 12 Personenmonate (PM)) einzustellen. Die ungeforderte Projektleiterin Annina Ließmann bringt in allen APs ihre Kenntnisse und Erfahrungen mit ein, um den kontinuierlichen Projektfortschritt und den Projekterfolg auf inhaltlicher Ebene sicherzustellen. Es wird nun zu jedem Arbeitspaket auf die Zielsetzung, die Vorgehensweise, die erwarteten Ergebnisse und die erforderlichen personellen Ressourcen (PM) eingegangen.

4.1.1 AP-1 - Ist-Analyse (Monat 1–3)

Das erste Arbeitspaket analysiert die Ist-Situation beim Industriepartner. In einem ersten Schritt ist es wichtig, einen Einblick und Überblick in die verschiedenen Produktionsprozesse bei Zeiss SMT zu gewinnen. Hierfür ist ein Besuch vor Ort bei Zeiss SMT in Oberkochen geplant. Zudem sollen durch weitere Gespräche mit dem Industriepartner die bereits implementierten Methoden zur Optimierung der Produktion in Erfahrung gebracht werden. Diese können von rein statistischen Ansätzen bis hin zu Machine Learning Ansätzen reichen. Dabei können etwaige Ansätze unter Umständen als Basis für weitere Arbeitspakete dienen. Sollte dies der Fall sein, ist es wichtig zu wissen, wie diese bislang umgesetzt wurden. Ebenso werden die verfügbaren Produktionsdaten eruiert, welche die Grundlage dieses Projektes

darstellen. Je nachdem, ob Produktionsdaten verfügbar gemacht werden können und in welcher Form diese vorliegen, ergeben sich gegebenenfalls Anpassungen in den zukünftigen Arbeitspaketen. Somit ist das AP-1 essentiell, da alle weiteren Projektphasen und damit verbundene Entscheidungen auf dieser Ausgangssituation beruhen.

Personelle Ressourcen

- Ungeförderter Projektleiter 0 PM
- Wissenschaftlicher Mitarbeiter 2 PM
- Studentische Hilfskraft 2 PM

Ergebnisse

- Aufnahme des Status-Quo beim Industriepartner
- Überblick zu bereits implementierten Lösungen in der Produktion
- Feststellung verfügbarer Produktionsdaten
- Schaffen einer Grundlage als Ausgangssituation für alle weiteren Arbeitspakete

4.1.2 AP-2 - Literatur Recherche (Monat 1–3)

Das zweite Arbeitspaket befasst sich mit der Recherche bestehender Literatur. Dabei soll das Arbeitspaket parallel zu AP-1 stattfinden. Im Gegensatz zu AP-1 soll hier nicht der Ist-Stand beim Industriepartner, sondern der Stand der Forschung und Literatur bezüglich der Verwendung von Process Monitoring Methoden zur Optimierung von Produktionsprozessen untersucht werden. Dabei wird vor allem auf die Unterscheidung von deskriptiven/diagnostischen, prädiktiven und präskriptiven Methoden Wert gelegt.

Personelle Ressourcen

- Ungeförderter Projektleiter 0 PM
- Wissenschaftlicher Mitarbeiter 1 PM
- Studentische Hilfskraft 2 PM

Ergebnisse

- Abbildung des Status-Quo in Forschung und Literatur hinsichtlich Optimierung von Produktionsprozessen mit Process Monitoring Methoden

4.1.3 AP-3 - Erarbeitung des Gesamtkonzeptes (Monat 4–7)

Das dritte Arbeitspaket baut auf AP-1 und AP-2 auf. Ziel ist es hierbei, ein Gesamtkonzept zur Optimierung von Produktionsprozessen mit Hilfe von Process Monitoring Ansätzen zu entwickeln. Nachdem also nun bekannt ist, welche Produktionsdaten und bisherigen Ansätze beim Industriepartner vorliegen und welche individuellen Ansätze bereits in der Forschung beschrieben werden, sollen die gewonnen Erkenntnisse aus diesen beiden Arbeitspaketen in AP-3 vereinigt werden. Dabei soll vor allem das Zusammenspiel von deskriptiven/diagnostischen, prädiktiven und präskriptiven Ansätzen berücksichtigt werden. Teil dieses Gesamtkonzeptes ist außerdem die Konkretisierung des relevanten Prozesses, zum Beispiel die Produktion eines bestimmten Produkts oder Teils. Je nach Datenlage können hier auch Produkte in Kategorien zusammengefasst werden. Mit dem erstellten Gesamtkonzept ist die Planungsphase des Projekts abgeschlossen und Meilenstein 1 erreicht. Zudem kann mit dem erstellten Gesamtkonzept und den identifizierten, potentiellen Anwendungsfällen beim Industriepartners beispielhaft Forschungsfrage 1 beantwortet werden.

Personelle Ressourcen

- Ungeförderter Projektleiter 0 PM
- Wissenschaftlicher Mitarbeiter 2 PM
- Studentische Hilfskraft 4 PM

Ergebnisse

- Festlegung des zu optimierenden Produktionsprozesse(s), Prozesskennzahlen sowie relevante Prozessdaten
- Gesamtkonzept zur Optimierung von Produktionsprozessen mit Process Monitoring Ansätzen

4.1.4 AP-4 - Deskriptives und diagnostisches Process Monitoring (Monat 8–12)

Nachdem das Gesamtkonzept in AP-3 erstellt wurde, beginnt mit diesem Arbeitspaket die erste Analyse Iteration nach PM² [25]. In dieser Iteration steht die deskriptive und diagnostische Analyse mit Hilfe von Process Mining für Process Monitoring. Da die Grundlage von Process Mining ein Event Log ist, muss dieser, je nach Datenlage, generiert und mit zusätzlichen Produktionsdaten angereichert werden. Anschließend werden verschiedene Methoden von Process Mining angewendet und für den Produktionskontext getestet, unter anderem Process Discovery und Conformance Checking. Mit dem Abschluss dieses Arbeitspakets ist Meilenstein 2 erreicht.

Personelle Ressourcen

- Ungeförderter Projektleiter 0 PM
- Wissenschaftlicher Mitarbeiter 2 PM
- Studentische Hilfskraft 5 PM

Ergebnisse

- Event Log für einen Produktionsprozess, angereichert mit zusätzlichen Produktionsdaten
- Entwicklung einer Methode für deskriptives/diagnostisches Process Monitoring in der Produktion
- Potentielle prototypische Implementierung gemäß dem Analyseergebnis und Evaluation

4.1.5 AP-5 - Vorausschauendes Process Monitoring (Monat 12–17)

Die zweite Iteration beschäftigt sich mit Methoden zum vorausschauenden Process Monitoring. Das bedeutet, die Vorhersage von relevanten Prozesskennzahlen bevor der Prozess abgeschlossen ist. Je eher im Prozessdurchlauf diese Vorhersage getroffen werden kann, desto mehr Zeit bleibt darauf zu reagieren. Deshalb wird in diesem Arbeitspaket zunächst analysiert, welche Kennzahlen sich in einem gegebenen Fertigungsprozess für eine Vorhersage eignen, um einen geeigneten Anwendungsfall zu identifizieren. Im Anschluss muss eine passende Predictive Process Monitoring Methode entwickelt werden. Dafür könnten bestehende Methoden aus der Literatur, modifiziert auf den Anwendungsfall, verwendet werden.

Für das Training von Machine Learning Methoden sind eine große Anzahl an Daten notwendig. Zusätzliche Sensordaten könnten die Vorhersagegenauigkeit verbessern. Sollte keine ausreichende Datenmenge zur Verfügung stehen, müssen mit der Expertise des Industriepartners zu Produktionsdaten geeignete Prozessdaten simuliert werden.

Mit dem Abschluss dieses Arbeitspakets wird Forschungsfrage 2 beantwortet und Meilenstein 3 erreicht.

Personelle Ressourcen

- Ungeförderter Projektleiter 0 PM
- Wissenschaftlicher Mitarbeiter 2 PM
- Studentische Hilfskraft 5 PM

Ergebnisse

- Identifikation von Anwendungsfällen in der Produktion
- Entwicklung einer Methode für vorausschauendes Process Monitoring
- Potentielle prototypische Implementierung gemäß dem Analyseergebnis und Evaluation

4.1.6 AP-6 - Empfehlungen zur Prozessoptimierung (Monat 17–22)

Die letzte Iteration beschäftigt sich mit Empfehlungen zur Prozessoptimierung. Prescriptive Process Monitoring Methoden geben Empfehlungen zu möglichen, alternativen Prozessverläufen während des Prozessdurchlaufs, um eine Kennzahl zu verbessern. Ähnlich wie bei AP-5 gilt es zunächst einen geeigneten Anwendungsfall innerhalb der Produktion zu identifizieren. Wenn ein Anwendungsfall für eine entsprechende Kennzahl eines Produktionsprozesses vorliegt, muss zum einen eruiert werden, wie Empfehlungen generiert werden können (zum Beispiel durch Anpassung bestehender Methoden oder andere Ansätze aus dem Machine Learning wie in 2.3 beschrieben) und zum anderen, wie diese evaluiert werden können. Nach der Bearbeitung von AP-6 kann Forschungsfrage 3 beantwortet werden. Mit dem Erreichen von Meilenstein 4 sind die Analyse Iterationen für dieses Projekt abgeschlossen.

Personelle Ressourcen

- Ungeförderter Projektleiter 0 PM
- Wissenschaftlicher Mitarbeiter 2 PM
- Studentische Hilfskraft 5 PM

Ergebnisse

- Identifikation von Anwendungsfällen in der Produktion
- Entwicklung einer Methode für Empfehlungen zur Prozessoptimierung
- Potentielle prototypische Implementierung gemäß dem Analyseergebnis und Evaluation

4.1.7 AP-7 - Evaluierung des Gesamtkonzeptes (Monat 23–24)

Nach den Analyse Iterationen in den Arbeitspaketen AP-4, AP-5 und AP-6 kann das Gesamtkonzept evaluiert werden. Hierzu werden zum einen die gewonnenen Erkenntnisse aus den einzelnen Arbeitspaketen herangezogen, zum anderen auch deren mögliche Kombination zum Monitoring eines Produktionsprozesses einer Machbarkeitsanalyse unterzogen. Dadurch ergeben sich konkrete Ansatzpunkte für eine Umsetzung von Process Monitoring in der Produktion und die wirtschaftliche Anschlussfähigkeit des vorliegenden Forschungsprojekts wird sichergestellt. Mit der Evaluation des Gesamtkonzeptes wird Forschungsfrage 4 beispielhaft beantwortet.

Personelle Ressourcen

- Ungeförderter Projektleiter 0 PM
- Wissenschaftlicher Mitarbeiter 1 PM
- Studentische Hilfskraft 2 PM

Ergebnisse

- Machbarkeitsanalyse zur Umsetzung von Process Monitoring Methoden in der Produktion
- Evaluationsbericht

4.1.8 AP-8 - Projektmanagement (Monat 1–24)

Das Projektmanagement stellt die zentrale Aufgabe der ungeförderten Projektleiterin dar. Durch das Projektmanagement soll ein erfolgreicher Projektabschluss sichergestellt werden.

Hierbei wird zwischen einem nach innen gerichteten und einem nach außen gerichteten Projektmanagement unterschieden. Das nach innen gerichtete Projektmanagement umfasst die Einhaltung von zeitlichen Fristen, die Vermittlung des Zeitplans, die Planung und Organisation von Besprechungen, die regelmäßige Kontrolle des aktuellen Status und die Förderung der Kommunikation zwischen dem wissenschaftlichen Mitarbeiter und der wissenschaftlichen Hilfskraft. Die Koordination mit dem ungeförderten Industriepartner erfolgt über die ungeförderte Projektleiterin. Das externe Projektmanagement umfasst zum einen die Erstellung von Zwischenberichten und die Anfertigung des Abschlussberichtes. Zum anderen beinhaltet es ebenso die wissenschaftliche Verwertung der erzielten Forschungsergebnisse in Form von Publikationen.

Personelle Ressourcen

- Ungeförderter Projektleiter 6 PM
- Wissenschaftlicher Mitarbeiter 0 PM
- Studentische Hilfskraft 0 PM

Ergebnisse

- Abstimmung mit dem Industriepartner
- Zwischenberichte
- Abschlussbericht
- Wissenschaftliche Publikationen
- Besuch von Konferenzen und Trainings in adressierter Domäne

4.2.3 Zuordnung von Personal zu Arbeitspaketen

In der Aufwandsabschätzung des geplanten Vorhabens wird zwischen drei Personalkategorien unterschieden: ungeförderte Projektleiterin (PL), wissenschaftliche Mitarbeitende (WiMi) und studentische Hilfskräfte mit Bachelorabschluss (BHK). Tabelle 1 fasst die zeitliche Zuordnung des Personals zu den Arbeitspaketen zusammen.

Tabelle 1: Zuordnung von Personal in PM zu Arbeitspaketen

	AP-1	AP-2	AP-3	AP-4	AP-5	AP-6	AP-7	AP-8	\sum PM
PL	0	0	0	0	0	0	0	6	6
WiMi (E13)	2	1	2	2	2	2	1	0	12
BHK (24h/Monat)	2	2	4	5	5	5	2	0	25

Die ungeförderte Projektleiterin wird in etwa 6 PM an Arbeit in das Projektvorhaben investieren. Die Projektleiterin ist für die Organisation und Administration des Projektes verantwortlich, welche kontinuierlich parallel zu den restlichen Arbeitspaketen abläuft. Daher werden die Personenmonate alle in Arbeitspaket 8 mit 20 Stunden pro Monat veranschlagt. Darunter fallen auch die Beratung und Betreuung von WiMi und BHK als auch die Kommunikation mit dem fachlichen Betreuer auf Seiten des Industriepartners.

Der wissenschaftliche Mitarbeiter wird für einen Zeitraum von 24 Monaten mit einer zeitlichen Auslastung von 50% (24 Monate \times 0.5 = 12 Monate) (E13 Stufe 2 inkl. Jahressonderzahlung (JSZ)) eingestellt.

Daneben ist der Einsatz studentischer Hilfskräfte von 6 Stunden pro Woche zur Unterstützung für die gesamte Projektdauer von zwei Jahren geplant. Da AP-1 und AP-2 parallel stattfinden wird der Einsatz einer weiteren Hilfskraft geplant. Zusätzlich ist die Unterstützung des Vorhabens durch ungeförderte studentische Arbeiten wie Abschlussarbeiten, Seminaren und Praktika vorgesehen.

4.3 Finanzplanung

Die eingeplanten Mittel des Projektes belaufen sich auf insgesamt 99.271,05 €. In Tabelle 2 sind die Einzelpositionen aufgelistet.

Tabelle 2: Finanzplanung

Finanzposten	Schlüssel	Einzelposten	Anzahl	Betrag	Ausgaben
Personal	0812	WiMi (E13 Stufe 2 + JSZ)	12 PM	6.087,44 €	73.049,19 €
	0822	BHK (6h/Woche)	25 PM	440,91 €	11.022,70 €
		Summe Personal			84.071,89 €
Dienstreisen	0846	Trainings und Veranstaltungen	5	270,00 €	1.350,00 €
	0846	SWC Summit	1	–	350,00 €
	0846	Reisen zum Industriepartner	6	180,00 €	1.080,00 €
	0846	BahnCard 50 (Business)	2	313,00 €	626,00 €
	0846	Konferenzen	3	–	7.313,00 €
		Summe Reisen			10.719,00 €
Sonstiges	0831	Software-Lizenz	2	179,00 €	358,00 €
	0850	Mobile Workstation (+ Dock)	1	–	4.122,16 €
		Summe Sonstiges			4.480,16 €
Gesamtkosten					99.271,05 €

Im weiteren Verlauf werden die aufgeführten Einzelposten im Detail erläutert.

4.3.1 Wissenschaftlicher Mitarbeiter

Für die Bearbeitung des Forschungsvorhabens wird ein entsprechend qualifizierter wissenschaftlicher Mitarbeiter eingestellt, welcher die wissenschaftlichen Herausforderungen in Projekt für eine Laufzeit von 24 Monaten bei einer Auslastung von 50% bearbeitet. Die Expertise dieses wissenschaftlichen Mitarbeiters trägt wesentlich zum Projekterfolg bei. Die Werte in Tabelle 2 beruhen auf der Entgeltgruppe 13 Stufe 2 des TV-L-Tabellenentgelts (für 2023), erhöht um 30% Arbeitgeberbeitrag zur Sozialversicherung (SV) (vom Bruttolohn). Die Jahressonderzahlung (JSZ) von etwa 50% des Monatssatzes ist ebenso mit einkalkuliert.

4.3.2 Studentische Hilfskraft

Für das Projekt werden zudem studentische Hilfskräfte eingestellt, die für die Projektlaufzeit von zwei Jahren am Projekt mitarbeiten. Die Arbeitszeit der studentischen Hilfskräfte beträgt 6 Stunden pro Woche zu einem Satz von 13,00€ angestellt (zzgl. SV). Insgesamt werden somit für die zwei Jahre 11.022,70€ für die studentischen Hilfskräfte fällig.

4.3.3 Dienstreisen

Im Rahmen des Software Campus sind mehrere Reisen zu Trainings sowie zum Software Campus Summit vorgesehen. Sämtlichen geplanten Ausgaben für die An- und Abreise in Deutschland liegt die Annahme zugrunde, dass die Reisen mit der Deutschen Bahn unter Verwendung einer BahnCard 50 erfolgen. Die geplanten Ausgaben für Übernachtungen basieren auf den Vorgaben der Bayerischen Landesreisekostenverordnung.

Insgesamt muss die Projektleiterin an sechs Trainings bei unterschiedlichen Industriepartnern teilnehmen, wofür jeweils Ausgaben für die An- und Abreise und zwei Übernachtungen anfallen. Die jeweiligen Veranstaltungsorte liegen zwischen 200 und 400 km von Nürnberg entfernt. Einer der Industriepartner hat seinen Sitz in Nürnberg. Für das Training bei diesem Industriepartner fallen keine Kosten an. Für die weiteren fünf Trainings ergeben sich durchschnittliche Ausgaben für die An- und Abreise von 90 €. Zusätzlich sind jeweils Übernachtungen am Veranstaltungsort vorgesehen, für die Ausgaben in Höhe von jeweils 90 € veranschlagt werden. Daraus ergeben sich Ausgaben von 270 € für jede Trainingsreise.

Neben den Trainings ist der Besuch des Software Campus Summit für den Abschluss des Vorhabens vorgesehen. Für die Teilnahme ist für die An- und Abreise mit der Bahn 110€ vorgesehen. Darüber hinaus sind zwei Übernachtungen mit jeweils 120€ vorgesehen (in Berlin). Dadurch ergibt sich eine Gesamtsumme von 350€.

Zusätzlich werden zur Abstimmung mit dem Industriepartner sechs Reisen mit Übernachtung eingeplant. Die Hin- und Rückfahrt (Bahn) wird mit 90€ angesetzt und für Übernachtungen werden jeweils 90€ eingeplant, wodurch geplante Gesamtausgaben von 180€ je Reise entstehen. Um niedrige Ausgaben für die An- und Abreise der Projektleiterin zu den verschiedenen Veranstaltungen des Software Campus zu gewährleisten, ist die Anschaffung einer BahnCard 50 (Business, 2. Klasse) geplant. Die BahnCard kostet jährlich 313,00€ (siehe Kapitel 6.1). Somit betragen die Gesamtkosten für die Anschaffung der zwei BahnCards im Projektzeitraum 626,00€.

Während der Projektlaufzeit ist es geplant die Ergebnisse auf drei renommierten Konferenzen vorzustellen. Anregungen, die sich aus dortigen Diskussionen ergeben, sollen gezielt für den weiteren Projektverlauf genutzt werden. In Summe werden 7.312,00€ für Konferenzen beantragt. Tabelle 3 listet die geschätzten Kosten je Konferenz auf.

Tabelle 3: Geschätzte Kosten für Konferenzen

Bezeichnung	Ort	Gebühr	Reise	Hotel	Tagegeld	Dauer	Gesamt
<i>BPM 2024</i>	Krakau, Polen	650,00 €	220,00 €	86,00 €	22,00 €	4 Tage	1.302,00 €
<i>ICIS 2024</i>	Bangkok, Thailand	750,00 €	1.100,00 €	110,00 €	31,00 €	5 Tage	2.555,00 €
<i>HICSS 2024</i>	Hawaii, USA	800,00 €	1.500,00 €	182,00 €	49,00 €	5 Tage	3.455,00 €
						Summe	7.312,00 €

4.3.4 Sonstiges

Zudem entstehen sonstiges Ausgaben für Lizenzen. Hier soll eine Lizenz für das Programm Overleaf angeschafft werden. Dies verursacht Kosten in Höhe von 358,00 € für zwei Jahre. Im Anhang ist der Screenshot hierzu zu finden (siehe Kapitel 6.2).

Das geplante Projekt umfasst einige rechenintensive Lernaufgaben, vor allem durch die Einbeziehung von Sensordaten in AP-5 und AP-6 für prädiktives und präskriptive Process Monitoring. Da Hochleistungsrechner an der Einrichtung nur beschränkt zur Verfügung stehen, beantragen wir eine mobile Workstation, die einerseits die erforderliche Leistungsfähigkeit für die rechenintensiven Lernaufgaben aufweist, gleichzeitig aber auch die mobile Arbeit zur Laufzeit ermöglicht. Die ausgewählte mobile Workstation ist mit einem 12-Kern Prozessor (CPU) für schnelle Hochleistungsberechnungen, 64 GB Arbeitsspeicher (RAM) und einer leistungsstarken Grafikkarte (38-Kern GPU) für die Modellbildung ausgestattet. Weitere Einzelheiten befinden sich im Anhang (siehe Kapitel 6.3). Zusätzlich bitten wir um die Finanzierung einer Thunderbolt 4 Dockingstation für den Anschluss der erforderlichen Peripheriegeräte wie Monitore und externe Festplattenlaufwerke. Letztere Peripheriegeräte werden als Grundausstattung voraussichtlich durch die Einrichtung gestellt. Die ausgewählte mobile Workstation mit dem Dock wird 3.464,00 € vor Steuern und 4.122,16 € nach Steuern (19%) kosten.

5 Verwertungsplan

Dieser Abschnitt stellt die Chancen der Verwertung der entstandenen Erkenntnisse, Lösungen und Software dar. Zunächst wird beschrieben, wie Ergebnisse des Projekts in die aktuellen Arbeiten des Projektpartners einfließen können (vgl. Kapitel 5.1). Danach werden die zu erwartenden wissenschaftlichen Erkenntnisse diskutiert (vgl. Kapitel 5.2) sowie auf dem Projekt aufbauende weiterführende Arbeiten und Ideen vorgestellt (vgl. Kapitel 5.3).

5.1 Wirtschaftliche Erfolgsaussichten

Das Vorhaben beschäftigt sich mit der Schnittstelle von Process Monitoring und Machine Learning im Produktionskontext. Gerade in digitalisierten Produktionsprozessen, in dem zum Beispiel innerhalb von Industrie 4.0 Dinge in den Produktionsprozess eingreifen können (IIoT), kann Process Monitoring erheblich zur Visualisierung, Analyse und letztendlich Verbesserung der Produktion beitragen. Das in diesem Projekt erstellte Konzept analysiert und evaluiert exemplarisch drei Ansätze von Process Monitoring und zeigt auf, welche Ansätze Unternehmen wie Zeiss SMT im Produktionsumfeld umsetzen können und welche Voraussetzung für die Umsetzung bestehen.

5.2 Wissenschaftlich-technische Erfolgsaussichten

Die Ergebnisse des Projektes werden auf unterschiedlichen Konferenzen und Fachtagungen vorgestellt. Die Veröffentlichung in den zugehörigen Tagungsbänden und weiteren Publikationsorganen mit wissenschaftlichen Begutachtungsprozessen ist der Hauptaugenmerk der wissenschaftlich-technischen Ziele. Der Besuch von Konferenzen dient dazu wissenschaftliche Ergebnisse mit Fachleuten zu diskutieren, neue Forschungskontakte zu knüpfen und aktuelle Ideen in der Forschung zu sammeln. Die Forschungsergebnisse fließen zudem in das Promotionsvorhaben der ungeforderten Projektleiterin ein. Die Publikation der Ergebnisse wird durch die Verpflichtungen im Rahmen der Dissertation sichergestellt. Durch die Expertise des Industriepartners Zeiss SMT im Produktionsumfeld sowie die Vorarbeiten des Lehrstuhls im Bereich prädiktives und präskriptives Process Monitoring bestehen deutlich erkennbare Erfolgsaussichten.

5.3 Wissenschaftliche und wirtschaftliche Anschlussfähigkeit

Sowohl prädiktives als auch präskriptives Process Monitoring sind verhältnismäßig junge Themen, die momentan in der Forschung, aber auch in der Praxis enorm an Aufmerksamkeit gewinnen. Kleine und mittelständische Unternehmen haben allerdings oft nicht die Mittel, sich dem Einsatz und der Einführung dieser Technologien zu widmen und so beschäftigten sich aktuell maßgeblich große Unternehmen und Konzerne mit dem Thema. Das Projekt eruiert mögliche Anwendungsfälle in der Produktion und zeigt damit Möglichkeiten auf, Process Monitoring Ansätze in weiteren Folgeprojekten im Produktionskontext zu implementieren. Somit ist gewährleistet, dass die Projektergebnisse sowohl von Zeiss SMT als auch von anderen, kleineren Unternehmen in der Industrie weiter verwendet werden können.

Der Lehrstuhl für Digital Industrial Service Systems, als Teil des Instituts für Wirtschaftsinformatik, ist eng in die Ausbildung der Studierenden, insbesondere im Bachelor Wirtschaftsinformatik und Master International Information Systems eingebunden, weshalb auch hier zweifelsohne Anschlussfähigkeit besteht. Die Erkenntnisse aus dem Projekt können einerseits in Seminaren und Vorlesungen an die Studierenden weitergegeben werden, andererseits können sie auch als Grundlage für Abschlussarbeiten dienen, in welchen weiterführende Aspekte und Forschungsfragen untersucht werden. Zudem ist denkbar, dass sowohl das erarbeitete Konzept zur Optimierung von Produktionsprozessen mit Process Monitoring als auch implementierte Artefakte beispielsweise als modulares *“Process Monitoring as a Service”* angeboten werden kann und gegebenenfalls in einem weiteren Schritt in einer Ausgründung verwertet wird.

6 Anhang

6.1 BahnCard 50

BahnCard Business 50, 2. Klasse

Mit der BahnCard Business 50 fahren Sie ein Jahr lang stark vergünstigt und klimaneutral zu Ihren Geschäftsreisen.



Ihre Vorteile

- ✓ **50 % Rabatt** auf den Flexpreis und Flexpreis Business sowie **25 % Rabatt** auf den Super Sparpreis in der 2. Klasse
- ✓ **1. Geltungstag der Karte bis zu 180 Tage in der Zukunft wählbar**
- ✓ **Laufzeit endet automatisch** nach einem Jahr
- ✓ **Geschäftlich und privat nutzbar**
- ✓ **Rabatte auf viele Nahverkehrsangebote**

313 Euro

[Anmelden und bestellen](#)

6.2 Overleaf

Best Value

Standard

Great for shared projects

€228/yr

€179/yr

10 collaborators per project

All premium features
Sync with Dropbox and GitHub
Full document history
Track changes
+ more

[Buy Now!](#)

6.3 Mobile Workstation und Dock

PLAN.
BUILD.
PERFORM.

CANCOM

CANCOM GmbH - Messerschmittstraße 20 - 89343 Scheppach

Friedrich-Alexander Universität Erlangen-Nürnberg
Regionales RechenZentrum Erlangen (RRZE)
Hardware-Beschaffung
Frau Annina Liessmann
Martensstr. 1
91058 Erlangen

Angebotsnummer: 17815099-1, 3938/5882/7101
Angebotsdatum.....: 03.02.2023
Kundennummer: 39413
Ihre Anfragenummer.....: Anfrage MacBook Pro
Lieferart.....: General Logistic System
Seite.....: 1 von 1

Angebot

Lieferadresse

Friedrich-Alexander Universität
Erlangen-Nürnberg
Regionales RechenZentrum Erlangen (RRZE)
Hardware-Beschaffung
Martensstr. 1
91058 Erlangen

Rechnungsadresse

Friedrich-Alexander Universität
Erlangen-Nürnberg
Regionales RechenZentrum Erlangen (RRZE)
Hardware-Beschaffung
Martensstr. 1
91058 Erlangen

Artikelnr.	Beschreibung	Menge	Stückpreis	Betrag
9020580	Belkin CONNECT Thunderbolt 4 Dock Pro Dockingstation USB-C HDMI Herstellerartikelnummer: INC006VFSGY	1,00	309,00	309,00 € 1
10574699	Apple MacBook Pro Apple M2 Max 12-Core CPU 38-Core GPU Deutsch 64GB RAM 1TB SSD 35,6 cm (14") Spacegrau Beleuchtetes Magic Keyboard: Deutsch, 96W Herstellerartikelnummer: ctoMBP/D-383/Z17G	1,00	3.155,00	3.155,00 € 1

Nettobetrag 3.464,00 €
19,00% MwSt auf 3.464,00 € 658,16 €
Gesamtsumme 4.122,16 €

Vereinbarte Zahlungsart: Überweisung innerhalb von 30 Tagen netto.

Soweit nichts anderes vereinbart ist, erfolgen unsere Lieferungen und Leistungen auf Grundlage der Ergänzenden Vertragsbestimmungen für die Beschaffung von IT-Leistungen (EVB-IT).

Hinweis: Die Auftragserteilung erfolgte in Kenntnis der Covid-19-Pandemie und ihrer möglichen Auswirkungen auf das Wirtschaftsleben. Wir weisen Sie daher darauf hin, dass es bei der Ausführung des Auftrags aufgrund der konkreten Auswirkungen der Covid-19-Pandemie insbesondere in zeitlicher Hinsicht zu Behinderungen und Einschränkungen kommen kann, die von uns nicht zu vertreten sind.

Die Lieferung erfolgt frachtfrei.

Rahmenvertragsteam RV Apple BY
E-Mail: bayern.apple@cancom.de
Telefon: +49 8225 996-1599, Telefax: +49 8225 996-41599

CANCOM GmbH
Messerschmittstraße 20
89343 Scheppach
Tel: +49 8225 996-0
Fax: +49 8225 996-1033

Sitz der Gesellschaft ist:
Jettingen-Scheppach
Registergericht HRB 10653
Amtsgericht Memmingen
St. Nr. 151/116/01132
Ust-ID-Nr. DE 12 879 1177

Geschäftsführer:
Rüdiger Rath (Vorsitzender)
Paul Holdtschik
Andreas Holme
Ralf Hensei
Torsten Otto

Commerzbank Augsburg
IBAN: DE17 7204 0046 0112 9212 00
BIC: COBADEFFXXX

Deutsche Bank Augsburg
IBAN: DE90 7207 0001 0025 3740 00
BIC: DEUTDE33HAN

Literatur

- [1] Bitkom (2022). Industrie 4.0 - so digital sind Deutschlands Fabriken 2022. <https://www.bitkom.org/Presse/Presseinformation/Mehr-Nachhaltigkeit-in-Produktion-durch-Industrie-40>.
- [2] Breuker, D. and Matzner, M. (2013). Statistical Sequence Analysis For Business Process Mining And Organizational Routines. In *ECIS 2013 Completed Research*.
- [3] Breuker, D., Matzner, M., Delfmann, P., and Becker, J. (2016). Comprehensible predictive models for business processes. *MIS Quarterly*, 40(4):1009–1034.
- [4] De Weerd, J. and Wynn, M. T. (2022). Foundations of Process Event Data. In van der Aalst, W. M. P. and Carmona, J., editors, *Process Mining Handbook*, Lecture Notes in Business Information Processing, pages 193–211. Springer International Publishing, Cham.
- [5] Di Francescomarino, C. and Ghidini, C. (2022). Predictive Process Monitoring. In van der Aalst, W. M. P. and Carmona, J., editors, *Process Mining Handbook*, Lecture Notes in Business Information Processing, pages 320–346. Springer International Publishing, Cham.
- [6] Di Francescomarino, C., Ghidini, C., Maggi, F. M., and Milani, F. (2018). Predictive Process Monitoring Methods: Which One Suits Me Best? In Weske, M., Montali, M., Weber, I., and vom Brocke, J., editors, *Business Process Management*, Lecture Notes in Computer Science, pages 462–479, Cham. Springer International Publishing.
- [7] Drod, C., Weinzierl, S., Matzner, M., and Delfmann, P. (2021). The Recommender: A decision support tool for Predictive Business Process Monitoring.
- [8] Dumas, M., La Rosa, M., Mendling, J., and Reijers, H. A. (2018). *Fundamentals of Business Process Management*. Springer, Berlin, Heidelberg, 1st edition.
- [9] Gartner (2014). Gartner Says Advanced Analytics Is a Top Business Priority. <https://www.gartner.com/en/newsroom/press-releases/2014-10-21-gartner-says-advanced-analytics-is-a-top-business-priority>.
- [10] Grüger, J., Malburg, L., Mangler, J., Bertrand, Y., Rinderle-Ma, S., Bergmann, R., and Asensio, E. S. (2022). SensorStream: An XES Extension for Enriching Event Logs with IoT-Sensor Data. arXiv:2206.11392 [cs].
- [11] Hüllermeier, E. (2021). Prescriptive Machine Learning for Automated Decision Making: Challenges and Opportunities. arXiv:2112.08268 [cs].
- [12] Janiesch, C., Koschmider, A., Mecella, M., Weber, B., Burattin, A., Di Ciccio, C., Fortino, G., Gal, A., Kannengiesser, U., Leotta, F., Mannhardt, F., Marrella, A., Mendling, J., Oberweis, A., Reichert, M., Rinderle-Ma, S., Serral, E., Song, W., Su, J., Torres, V., Weidlich, M., Weske, M., and Zhang, L. (2020). The Internet of Things Meets Business Process Management: A Manifesto. *IEEE Systems, Man, and Cybernetics Magazine*, 6(4):34–44. Conference Name: IEEE Systems, Man, and Cybernetics Magazine.
- [13] Kellner, D. (2022). Causal Machine Learning - New Opportunities for Information Systems Research. In *PACIS 2022 Proceedings*.
- [14] Lechner, P. (2020). BMW: Process Mining @ Production. In Reinkemeyer, L., editor, *Process Mining in Action: Principles, Use Cases and Outlook*, pages 65–73. Springer International Publishing, Cham.
- [15] Leoni, M. d., Dees, M., and Reulink, L. (2020). Design and Evaluation of a Process-aware Recommender System based on Prescriptive Analytics. In *2020 2nd International Conference on Process Mining (ICPM)*, pages 9–16.

- [16] Leontjeva, A., Conforti, R., Di Francescomarino, C., Dumas, M., and Maggi, F. M. (2015). Complex Symbolic Sequence Encodings for Predictive Monitoring of Business Processes. In Motahari-Nezhad, H. R., Recker, J., and Weidlich, M., editors, *Business Process Management*, Lecture Notes in Computer Science, pages 297–313, Cham. Springer International Publishing.
- [17] Liebenberg, M. and Jarke, M. (2020). Information Systems Engineering with Digital Shadows: Concept and Case Studies. In Dustdar, S., Yu, E., Salinesi, C., Rieu, D., and Pant, V., editors, *Advanced Information Systems Engineering*, Lecture Notes in Computer Science, pages 70–84, Cham. Springer International Publishing.
- [18] Matzner, M. and Scholta, H. (2014). Process Mining Approaches to Detect Organizational Properties in Cyber-Physical Systems.
- [19] Metzger, A., Neubauer, A., Bohn, P., and Pohl, K. (2019). Proactive Process Adaptation Using Deep Learning Ensembles. In Giorgini, P. and Weber, B., editors, *Advanced Information Systems Engineering*, Lecture Notes in Computer Science, pages 547–562, Cham. Springer International Publishing.
- [20] Márquez-Chamorro, A. E., Resinas, M., and Ruiz-Cortés, A. (2018). Predictive Monitoring of Business Processes: A Survey. *IEEE Transactions on Services Computing*, 11(6):962–977. Conference Name: IEEE Transactions on Services Computing.
- [21] Schwegmann, B., Matzner, M., and Janiesch, C. (2013). A Method and Tool for Predictive Event-Driven Process Analytics. In *Wirtschaftsinformatik Proceedings 2013*.
- [22] Teinemaa, I., Tax, N., de Leoni, M., Dumas, M., and Maggi, F. M. (2018). Alarm-Based Prescriptive Process Monitoring. In Weske, M., Montali, M., Weber, I., and vom Brocke, J., editors, *Business Process Management Forum*, Lecture Notes in Business Information Processing, pages 91–107, Cham. Springer International Publishing.
- [23] van der Aalst, W. M. P. (2016). *Process Mining: Data Science in Action*. Springer-Verlag Berlin Heidelberg, 2nd edition.
- [24] van der Aalst, W. M. P., Brockhoff, T., Ghahfarokhi, A. F., Pourbafrani, M., Uysal, M. S., and van Zelst, S. J. (2021). Removing Operational Friction Using Process Mining: Challenges Provided by the Internet of Production (IoP). In Hammoudi, S., Quix, C., and Bernardino, J., editors, *Data Management Technologies and Applications*, Communications in Computer and Information Science, pages 1–31, Cham. Springer International Publishing.
- [25] van Eck, M. L., Lu, X., Leemans, S. J. J., and van der Aalst, W. M. P. (2015). PM2: A Process Mining Project Methodology. In Zdravkovic, J., Kirikova, M., and Johannesson, P., editors, *Advanced Information Systems Engineering*, Lecture Notes in Computer Science, pages 297–313, Cham. Springer International Publishing.
- [26] Weinzierl, S., Dunzer, S., Zilker, S., and Matzner, M. (2020a). Prescriptive Business Process Monitoring for Recommending Next Best Actions. In Fahland, D., Ghidini, C., Becker, J., and Dumas, M., editors, *Business Process Management Forum*, Lecture Notes in Business Information Processing, pages 193–209, Cham. Springer International Publishing.
- [27] Weinzierl, S., Zilker, S., Brunk, J., Revoreda, K., Matzner, M., and Becker, J. (2020b). XNAP: Making LSTM-Based Next Activity Predictions Explainable by Using LRP. In Del Río Ortega, A., Leopold, H., and Santoro, F. M., editors, *Business Process Management Workshops*, Lecture Notes in Business Information Processing, pages 129–141, Cham. Springer International Publishing.