



Predictive Maintenance in österreichischen Unternehmen – Österreich Studie 2018

Umfrageergebnisse der Studie zum Status Quo der Umsetzung
von Predictive Maintenance in österreichischen Unternehmen



Gemeinsam durchgeführt von IPN & ÖVIA

Executive Summary

Mehr als 50 Führungskräfte und Fachspezialisten aus dem Bereich Wartung und Instandhaltung haben an der Umfrage **“Predictive Maintenance in österreichischen Unternehmen“** teilgenommen.

Gefragt nach dem Reifegrad von Predictive Maintenance (PdM) attestieren sich 31% der teilnehmenden Unternehmen einen „Hohen Reifegrad“, 45% schätzen den Reifegrad als „Mittel“ ein und nur 24% geben einen „Niedrigen Reifegrad“ an. Basierend auf den Ergebnissen der Reifegradbewertung beleuchtet diese Umfrage verschiedene Themengebiete wie die Treiber für PdM-Initiativen, die eingesetzten Technologien und die organisatorische Umsetzung. Ebenso wird der Frage nachgegangen, welche Form von PdM von den Unternehmen angewendet wird. Dabei wird zwischen einer „traditionellen“ und einer „Big Data“ zentrierten Herangehensweise unterschieden.

Die wichtigsten Ergebnisse aus der Studie sind:

- Kosten- und Verfügbarkeitsthemen sind die primären Treiber von PdM-Initiativen.
- Unternehmen mit einem hohen Reifegrad verwenden vielfältigere Datenquellen und Technologien für die Zustandsprognose der Maschinen als Unternehmen mit einem niedrigen Reifegrad.
- Spezielle Data Science Software und Cloud IoT-Plattformen werden bisher nur in einem geringem Ausmaß verwendet.
- PdM wird hauptsächlich durch Instandhaltungspersonal und Personal aus den technischen Fachbereichen betrieben. Spezielle Fachleute aus dem Bereich „Data Science“ sind nur in wenigen Fällen verfügbar bzw. an der Umsetzung von PdM beteiligt.
- Technologiepartner und Universitäten sind die wichtigsten Partner bei der Umsetzung von PdM-Projekten.
- Die Zufriedenheit mit den Ergebnissen von PdM steigt mit dem Reifegrad der Unternehmen.
- Unternehmen mit niedrigem Reifegrad sehen die größten Hindernisse bei der Einführung von PdM in fehlendem Know-How, begrenzten technischen Ressourcen und mangelnder Verfügbarkeit von relevanten Daten.

Da die Umsetzung von PdM die Unternehmen immer wieder vor große Herausforderungen stellt, findet sich im zweiten Abschnitt dieser Studie das von IPN entwickelte, praxiserprobte Vorgehensmodell, das die einzelnen Phasen eines PdM Projekts darstellt und in den wesentlichen Punkten erläutert.

90%

der befragten Führungskräfte gaben an, dass sich ihr Unternehmen bereits mit Predictive Maintenance beschäftigt.

Inhaltsverzeichnis

EINLEITUNG	1
PERSÖNLICHE (SUBJEKTIVE) EINSCHÄTZUNG DES PREDICTIVE MAINTENANCE REIFEGRADES	2
ZIELSETZUNGEN, DIE MIT PREDICTIVE MAINTENANCE VERFOLGT WERDEN	4
ORGANISATION DER BETRIEBLICHEN UMSETZUNG VON PREDICTIVE MAINTENANCE	6
I. Daten, die für die Zustandserfassung erhoben werden	6
II. Technologien, die für die Zustandserfassung eingesetzt werden	8
III. Methoden, die für die Zustandserfassung zum Einsatz kommen	10
IV. IT-Infrastruktur, die für Predictive Maintenance zum Einsatz kommt	11
V. An der Umsetzung von Predictive Maintenance beteiligte Funktionen	13
VI. Partner für die Umsetzung von Predictive Maintenance	14
ZUFRIEDENHEIT MIT DEN ERGEBNISSEN VON PREDICTIVE MAINTENANCE	16
HINDERNISSE BEI DER EINFÜHRUNG VON PREDICTIVE MAINTENANCE	18
FÜHREN SIE IHR PREDICTIVE MAINTENANCE PROJEKT ZUM ERFOLG	22
Das IPN Vorgehensmodell	22
Phase 1 – „Die Planung zum Erfolg!“	23
Phase 2 – „Was machen wir mit den Daten?“	27
Phase 3 – „Welche Technologie benötigen wir?“	29
STUDIENDATEN	31

EINLEITUNG

Predictive Maintenance (PdM) – „die vorausschauende Instandhaltung“ – ist ein Kernstück der Industrie 4.0. Um die Instandhaltung aller Betriebsmittel sicherzustellen, wurde bisher auf statisch ausgerichtete, kostenzentrierte Instandhaltungsstrategien mit zumeist reaktiver Störungsbeseitigung und intervallbasierten präventiven Aktivitäten gesetzt. An Stelle dieses Strategiemixes aus reaktiven und vorbeugenden Instandhaltungstätigkeiten tritt ein agiles, proaktives Vorgehen. Dabei macht sich PdM die große Datenvielfalt und -menge in der produzierenden Industrie zunutze, um Prognosen hinsichtlich des Ausfallverhaltens der Betriebsmittel zu erstellen.

Für die Analyse der anfallenden Daten kommen zunehmend Methoden des maschinellen Lernens und daraus entwickelte Data-Mining-Algorithmen zum Einsatz. Die Anwendung dieser Methoden ist keineswegs trivial und benötigt ein Zusammenspiel aus Domänenwissen, Expertenwissen im Bereich Data Mining und umfangreiches Wissen bezüglich Sensorik bzw. Schnittstellenmanagement.

Mit der gegenständlichen Umfrage haben IPN – Intelligent Predictive Networks GmbH und ÖVIA („Österreichische Vereinigung für Instandhaltung und Anlagenwirtschaft“) erhoben, wie es um die „Umsetzung von Predictive Maintenance (PdM) in österreichischen Unternehmen“ bestellt ist. Die Umfrageergebnisse werden auf den folgenden Seiten präsentiert und kommentiert.

Anmerkung Rundungsdifferenzen: Aufgrund der automatisierten Datenübernahme kann es in Einzelfällen zu Rundungsdifferenzen kommen.

Aus Gründen der besseren Lesbarkeit wird in dieser Studie die Sprachform des generischen Maskulinums angewendet. Es wird an dieser Stelle darauf hingewiesen, dass die ausschließliche Verwendung der männlichen Form geschlechtsunabhängig verstanden werden soll.

PERSÖNLICHE (SUBJEKTIVE) EINSCHÄTZUNG DES PREDICTIVE MAINTENANCE REIFEGRADES

Zu Beginn der Umfrage wurden die Teilnehmer gebeten, eine persönliche Einschätzung des Reifegrads hinsichtlich Predictive Maintenance in ihrem Unternehmen abzugeben.

Die Teilnehmer konnten aus fünf Optionen wählen:

1. **Level 0 (Nicht vorhanden):** Unser Unternehmen hat sich mit PdM noch nicht auseinandergesetzt.
2. **Level 1 (Beginner):** Erste „Idee“ Industrie 4.0 zu machen, jedoch noch keine Vorstellung davon, was PdM leisten kann. Noch keine Datenbasis und kein Know-How im Bereich Predictive Analytics vorhanden.
3. **Level 2 (Intermediate):** Erste Überlegungen hinsichtlich der Anwendungsfälle von PdM angestellt. Unstrukturierte, über verschiedene Datenquellen verteilte Datenbasis für erste Analysen vorhanden. Kein, oder nur geringes Know-How im Bereich Predictive Analytics vorhanden. Erste Analysen mit Ausschnitten aus der vorhandenen Datenbasis durchgeführt.
4. **Level 3 (Advanced):** Konkrete Anwendungsfälle für PdM identifiziert und dokumentiert. Datenbasis und gezielte Datenerfassung vorhanden bzw. gestartet. Grundlegendes Know-How im Bereich Predictive Analytics vorhanden. Regelmäßige Durchführung von Analysen und erste Versuche mit Prognosemodellen gestartet.
5. **Level 4 (Expert):** Konkrete Anwendungsfälle für PdM identifiziert und dokumentiert. Datenbasis und gezielte Datenerfassung vorhanden und kontinuierlich durchgeführt. Tiefgehendes Know-How im Bereich Predictive Analytics vorhanden. Regelmäßige Durchführung von Analysen und Prognosemodelle in der operativen Umsetzung von PdM verankert.

Die Teilnehmer haben folgende Einschätzung zum Reifegrad abgegeben:

Level 0 – nicht vorhanden	10%
Level 1 – Beginner	14%
Level 2 – Intermediate	45%
Level 3 – Advanced	25%
Level 4 – Expert	6%

In der Auswertung wurden „Level 0 – Level 1“ als „**Niedriger Reifegrad**“, „Level 2“ als „**Mittlerer Reifegrad**“ und „Level 3 – Level 4“ als „**Hoher Reifegrad**“ zusammengefasst.

Abbildung 1 zeigt, wie die Befragten den Reifegrad ihres Unternehmens einschätzen. 24% der Befragten attestieren ihrem Unternehmen einen „Niedrigen Reifegrad“, 45% einen „Mittleren Reifegrad“ und 31% einen „Hohen Reifegrad“.




Abbildung 1: Einschätzung des Umsetzungsgrades von PdM im eigenen Unternehmen

Diese 31% „hoher Reifegrad“ sind aus Sicht von IPN eine sehr optimistische Selbsteinschätzung und wir werden diese anhand konkreter Beispiele aus den Studienergebnissen näher beleuchten und gegebenenfalls auch hinterfragen. IPN führt PdM-Projekte in allen Größenklassen durch und hat die Erfahrung gemacht, dass sowohl in der Planung der konkreten Herangehensweise, als auch bei der Durchführung von PdM erst wenig Know-How in den Unternehmen vorhanden ist. Ein Grund für den hohen Wert könnte sein, dass die Teilnehmer die traditionelle Sichtweise von PdM für die Bewertung herangezogen haben. PdM in dieser Sichtweise bezieht sich auf die Überwachung des mechanischen Zustandes von Maschinen und Anlagen, sowie der Planung und Durchführung von Instandhaltungsaktivitäten basierend auf diesen, meist isoliert betrachteten, Zustandsparametern.

Predictive Maintenance in einer modernen Auffassung basiert auf einer „Big Data Sichtweise“. Eine Vielzahl unterschiedlichster Parameter (nicht nur Maschinenzustandsdaten) werden erfasst, mit Hilfe von statistischen Verfahren und Methoden des maschinellen Lernens (Machine Learning) ausgewertet und Prognosen über den Zustand der Maschinen und Anlagen erstellt. Auf diesem Weg lassen sich Störungen vorhersagen, *bevor* es zu Ausfällen kommt.

Die produzierende Industrie hat nach der Erfahrung von IPN erst wenige erfolgreiche Projekte hervorgebracht, die diesem modernen Paradigma gerecht werden.

Es ist daher fraglich, ob die moderne Sichtweise von PdM von den Teilnehmern für die Einschätzung des Reifegrads herangezogen wurde. Im Verlauf der weiteren Auswertung halten wir daher „Ausschau nach Hinweisen“, die unsere Zweifel bestätigen oder ausräumen.

Erfreulich ist, dass PdM in den Unternehmen angekommen ist. Nur 10% der Teilnehmer haben angegeben, dass PdM in ihrem Unternehmen noch kein Thema ist.

ZIELSETZUNGEN, DIE MIT PREDICTIVE MAINTENANCE VERFOLGT WERDEN




Abbildung 2: Zielsetzungen, die mit PdM verfolgt werden

Das wenig überraschende Ergebnis bei den Zielen war, dass die Kosten- und Verfügbarkeitsthematik der primäre Treiber von PdM-Initiativen ist. Die Erhöhung von Umsatz- und Marktanteilen wird in den PdM-Business Cases bisher noch nicht als Top-Priorität angesehen.

Auch IPN sieht bei seinen Kunden, dass diese klassischen Themen meist der Auslöser für PdM-Initiativen sind. Das ändert sich aber sehr oft im Lauf des Projektfortschritts. Nach der Datengewinnungs- und Datenaufbereitungsphase wird sehr rasch erkannt, welche „zusätzlichen Potentiale“ sich noch in den Daten befinden, die mittels geeigneter Visualisierungstechniken, Analysemethoden und Anwendung von Machine Learning Algorithmen realisiert werden können.

Es werden Möglichkeiten für die Verbesserung der Produkte erkannt, Ideen für neue Services und Dienstleistungen werden geboren und ein nicht zu vernachlässigender Faktor ist die Dokumentation und Systematisierung des Wissens über die eigenen Anlagen und Prozesse.

Beispiele für diese Potenziale:

- Ein Produktionsunternehmen identifiziert energieineffiziente Anlagenkomponenten (bspw. unpassende Dimensionierung von Motoren) und Prozessschwächen („Schieben“ von schädlichen Anlagenzuständen in nächste Schicht) in seiner Produktion.
- Ein Hersteller von Sonderfahrzeugen erhält Einblick in die tatsächliche Nutzung und Beanspruchung seiner Fahrzeuge und nutzt diese Informationen als Grundlage für die Auslegung einer E-Version seines Produktes.
- Ein Hersteller von Einstiegssystemen integriert seine Prüfstände in die PdM-Infrastruktur und entwickelt ergänzende, digitale Services (bspw. Zustandsindikatoren) für seine Produkte.

ORGANISATION DER BETRIEBLICHEN UMSETZUNG VON PREDICTIVE MAINTENANCE

In der Umfrage wurden die Unternehmen gebeten, Informationen über die Umsetzung von PdM in ihrem Unternehmen zu liefern. Abgefragt wurden:

- I. Arten von Daten, die für die Zustandserfassung der Maschinen und Anlagen erfasst werden,
- II. Technologien, die für die Zustandserfassung eingesetzt werden,
- III. Methoden, die für die Zustandserfassung verwendet werden,
- IV. IT-Infrastruktur, die für die Umsetzung von PdM zum Einsatz kommt,
- V. Funktionen, die an der Umsetzung von PdM beteiligt sind und
- VI. Partner, mit denen in PdM-Projekten zusammengearbeitet wird.

I. Daten, die für die Zustandserfassung erhoben werden




Abbildung 3: Arten von Daten, die erfasst werden

Je höher der Reifegrad, desto vielfältiger sind die Datenquellen, die für PdM herangezogen werden. Nicht ohne Grund, denn erfolgreiches PdM basiert auf einer Vielzahl von Daten, welche unterschiedliche Dimensionen der Anlagen beleuchten.

Die Erfassung von produkt- und prozessbezogenen Qualitätsdaten findet über alle Reifegradklassen hinweg – im Vergleich zu den anderen Datenklassen – in einem geringen Ausmaß statt.

Gerade diese Daten besitzen aber – abhängig vom Produktionsprozess - einen hohen bis sehr hohen Informationsgehalt hinsichtlich des Maschinenzustandes und/oder der darauf eingesetzten Produktionsmittel. Zum Beispiel bei einem Schleifprozess deutet die geringe Oberflächengüte darauf hin, dass die eingesetzten Schleifmittel abgenutzt sind, oder eine Nachjustierung der Maschine erfolgen muss. Die geringe Berücksichtigung von Qualitätsdaten könnte ein Hinweis darauf sein, dass der Fokus von PdM-Initiativen sehr stark auf eine direkte und isoliert betrachtete Erfassung von „Verschleiß“ ausgerichtet ist.

Auffällig aus Sicht von IPN sind die Unterschiede zwischen den Reifegradklassen bei der Erfassung von Peripherie- oder Umgebungsdaten. Erfahrungsgemäß nimmt bei Unternehmen mit einem höheren Reifegrad das Interesse und die Bereitschaft zu, die Ergebnisse durch die Hinzunahme zusätzlicher Datenquellen zu verbessern.

Die historischen Instandhaltungsdaten werden im Verhältnis zu deren Informationsgehalt „relativ wenig“ berücksichtigt. Das liegt mit hoher Wahrscheinlichkeit daran, dass die Qualität der Instandhaltungsaufzeichnungen (sehr oft händisch, mit unterschiedlichem Format und Detaillierungsgrad erfasst) eine automatisierte Auswertung nur schwer möglich macht. Das ist „bedauerlich“, denn die Instandhaltungshistorie stellt eine wichtige Datenquelle dar, beinhaltet sie doch die für PdM störungsrelevanten Ereignisse. Das Führen strukturierter und automatisiert verarbeitbarer Instandhaltungshistorien kann die Ergebnisse von PdM wesentlich verbessern und sollte daher mit hoher Priorität verfolgt werden.

II. Technologien, die für die Zustandserfassung eingesetzt werden

a) Technologien, die bereits eingesetzt werden




Abbildung 4a: Bereits eingesetzte Technologien für die Zustandserfassung

Je höher der Reifegrad, umso mehr unterschiedliche Technologien werden für die Zustandserfassung der Maschinen und Anlagen eingesetzt. Die „Klassiker“ elektrische Zustandsmessung, Vibrations-, Schmiermittel- und Infrarotanalyse herrschen vor. Zusätzlich genannt wurden noch Temperatur- und Druckmessungen, die häufig unter „sonstige Technologien“ angeführt wurden.

b) geplant, in den nächsten 3 Jahren einzuführen




Abbildung 4b: Technologien für die Zustandserfassung, die zukünftig eingesetzt werden

Bei den in den kommenden Jahren geplanten Technologien wird Akustik am häufigsten genannt.

In laufenden Projekten stößt IPN vermehrt auf das Themengebiet der „Körperschallmessung“. Von dieser Technologie erhoffen sich viele Unternehmen, dass diese bei der Erkennung von möglichen Ausfällen, insbesondere bei Lagerschäden, gute Resultate liefert. Allerdings ist diese Technologie teuer und setzt (meist) stationäre Anlagen voraus. Für IPN ist der Fokus auf diese Technologie ein Hinweis darauf, dass die Unternehmen dem „klassischen“ PdM-Ansatz folgen, da diese Technologie meist isoliert, zur Detektion eines spezifischen Fehlerbildes, eingesetzt wird.

III. Methoden, die für die Zustandserfassung zum Einsatz kommen

a) bereits eingesetzte Methoden für die Zustandserfassung




Abbildung 5a: Bereits eingesetzte Methoden für die Zustandsdatenerfassung

b) geplant, in den nächsten 3 Jahren einzuführen




Abbildung 5b: Zukünftig geplante Methoden für die Zustandsdatenerfassung

Je höher der Reifegrad, umso mehr kommen automatisierte Datenerfassungstechniken zum Einsatz. Der Trend bzw. der Ausbau der automatisierten Datenerfassung ist bei allen drei Reifegraden gegeben, denn die Grundlage von PdM – sowohl in der „klassischen“, als auch in der „modernen“ Herangehensweise – ist die Erfassung und Verarbeitung von großen Datenmengen. Insbesondere die immer detailliertere und großflächigere Überwachung von Produktionsanlagen, lässt sich nur durch den Einsatz von entsprechenden Technologien bewerkstelligen.

Zurückhaltung herrscht bei Wireless- und internetfähigen Sensoren. Praktische Erfahrungen haben gezeigt, dass diese Art von Sensorik einen großen Mehraufwand in der Integration und Wartung erzeugen (bspw. Einbindung in die IT Infrastruktur) und ein Sicherheitsrisiko darstellen (fehlende Sicherheitsupdates).

Bei den geplanten Technologien (Einführung in den kommenden drei Jahren) zeigt sich zwar, dass Wireless- und Internetsensoren vermehrt zum Einsatz kommen sollen, es bleibt aber abzuwarten, ob sich diese Technologien in einem „rauen“ Produktionsumfeld bewähren können.

IV. IT-Infrastruktur, die für Predictive Maintenance zum Einsatz kommt

a) bereits im Einsatz befindliche IT-Infrastruktur




Abbildung 6a: Bereits im Einsatz befindliche IT-Infrastruktur für PdM

Keine Überraschung ist der Einsatz von Microsoft-Produkten – vor allem Excel, das in inoffiziellen „Studien“ immer noch die führende Data Science Plattform ist. Der hohe Anteil von In-House Server- und Datenbankplattformen ist aller Wahrscheinlichkeit nach dem Umstand geschuldet, Produktionsdaten nicht „außer Haus“ geben zu wollen und dass viele Fragen in Bezug auf IT-Sicherheit und Compliance bei der Anbindung von Cloud-Umgebungen an die Produktions-IT noch nicht geklärt sind. Das Gleiche gilt für den hohen Anteil der für das Unternehmen speziell entwickelten Software. Ein Grund dafür könnte sein, dass die zur Verfügung stehenden Standard-Softwareprodukte nicht die Flexibilität bieten, die von den Unternehmen für die Umsetzung von PdM als erforderlich angesehen wird.

Besonders auffallend ist, dass spezielle Data Science Software kaum im Einsatz ist. Hier stellt sich die eingangs gestellte Frage, ob die Selbsteinschätzung von 31% hoher Reifegrad nicht zu optimistisch ist. Predictive Maintenance in einer modernen, Big-Data getriebenen Definition benötigt spezielle Software und Tools, welche für die Modellentwicklung und Anwendung von Machine Learning Algorithmen entwickelt wurden. Jedoch setzen gerade einmal 20% der Unternehmen mit einem hohen Reifegrad solche Softwarepakete ein, was darauf schließen lässt, dass sich die Reifegrad-Selbsteinschätzung auf einen traditionellen PdM-Ansatz bezieht¹.

b) geplant, in den nächsten 3 Jahren einzuführen




Abbildung 6b: IT-Infrastruktur, die zukünftig eingesetzt werden soll

¹ Es könnte auch sein, dass die speziell für die Unternehmen entwickelten Softwarepakete diese Predictive- und Machine Learning Funktionalitäten zur Verfügung stellen. Ob dies der Fall ist wurde in der Studie nicht erhoben.

Cloud-IoT Plattformen kommen relativ wenig zum Einsatz. In den kommenden 3 Jahren haben, bzw. planen ca. 50% der Unternehmen den Einsatz solcher Plattformen für PdM. Obwohl nicht explizit abgefragt, die praktische Erfahrung zeigt, dass die Unternehmen ihre sensiblen Maschinen- und Anlagendaten nicht (gerne) außer Haus geben. Außerdem stellt performanter Cloud-Speicher einen nicht zu unterschätzenden Kostenfaktor dar.

V. An der Umsetzung von Predictive Maintenance beteiligte Funktionen




Abbildung 7: An PdM beteiligte Funktionen

Für PdM kommen hauptsächlich Fachkräfte aus den Funktionsbereichen Wartung und Instandhaltung, Technik und IT zum Einsatz. Auch hier zeigt sich wieder die Diskrepanz zur hohen Reifegradeinschätzung (31%) und der betrieblichen Praxis. Data Scientists sind mit nur 33% bei den Unternehmen mit hohem Reifegrad vertreten. D.h., dass nur jedes dritte Unternehmen – das sich einen hohen Reifegrad attestiert – auf entsprechende „Daten-Fachkräfte“ zurückgreifen kann. Ob diese Spezialistenfunktion, die durch Data Scientists zur Verfügung gestellt wird, durch Fachkräfte aus anderen Bereichen abgedeckt werden kann, ist fraglich.

Eventuell bedienen sich die Unternehmen externer Spezialisten, die ein tiefgehendes Know-How im Bereich Predictive Analytics mitbringen.

VI. Partner für die Umsetzung von Predictive Maintenance

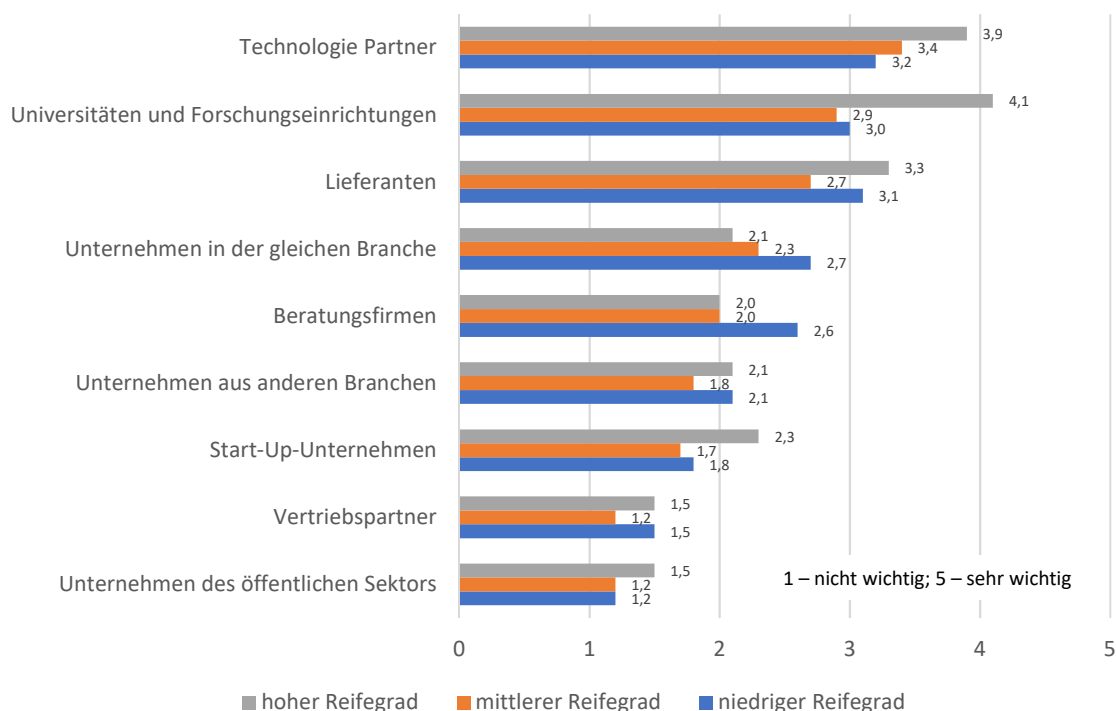


Abbildung 8: Partner für die Umsetzung von PdM

Technologiepartner stehen bei der „Wichtigkeit“ an erster Stelle. Häufig stellt die Einführung und die Erweiterung von PdM nicht die Kernkompetenz des Unternehmens dar und die Unternehmen erwarten sich von ihren Technologiepartnern den größten Beitrag in der Umsetzung von PdM. Die speziellen, kundenspezifischen Anforderungen müssen durch entsprechende Technologien unterstützt werden und daher ist es wenig überraschend, dass den Technologiepartnern der höchste Stellenwert eingeräumt wird.

An dieser Stelle sei auch noch darauf hingewiesen, dass solche Partnerschaften über die reine Technologie hinausgehen. Speziell in der Kunden-Lieferanten-Kette gilt es zu klären, wie das „Data-Ownership“ zwischen den Unternehmen gestaltet wird. Jeder der Partner hat ein (berechtigtes) Interesse, auf die in solchen Projekten generierten Daten zuzugreifen und die daraus gewonnen Erkenntnisse zu nutzen, um die eigenen Produkte besser zu verstehen, zu optimieren und neue Services zu entwickeln.

Erfreulich ist auch, dass sich die Universitäten ganz vorne bei den wichtigen Partnern einreihen. Wie es scheint, sind die Universitäten „nahe an der Wirtschaft“ und diese Lehr- und Forschungsstätten werden durch die Konzentration von Wissen und Methodenkompetenz von den Unternehmen gerne für PdM-Projekte in Anspruch genommen.

Grad der Zusammenarbeit mit externen Partnern




Abbildung 9: Zusammenarbeit mit externen Partnern für die Umsetzung von PdM

Die interne und externe Zusammenarbeit ist wichtig. Unternehmen mit hohem Reifegrad arbeiten stärker über die Grenzen der Firma hinaus zusammen, nutzen breitere Lern- und Innovationsnetze und nehmen Zulieferer und andere Partner mit auf die Reise. Dies erfordert, dass sich Unternehmen ihrer eigenen Stärken bewusst sind und gleichermaßen ihre Schwächen kennen. Bei Letzterem gilt es, sich mit externer Hilfe weiterzuentwickeln, um die sich bietenden Potentiale auszuschöpfen.

Bei Unternehmen mit niedrigem Reifegrad ist die Zusammenarbeit mit externen Partnern am wenigsten weit fortgeschritten. Dies dürfte der fehlenden Erfahrung mit PdM und dem dafür benötigten Know-How geschuldet sein. Die Erfahrung von IPN zeigt auch, dass häufig erste interne Initiativen gestartet werden und erst bei kritischem Projektverlauf oder kurz vor einem Fehlschlag externe Spezialisten mit ins Boot geholt werden.

ZUFRIEDENHEIT MIT DEN ERGEBNISSEN VON PREDICTIVE MAINTENANCE




Abbildung 10: Zufriedenheit mit den Ergebnissen von PdM

Die Zufriedenheit steigt mit dem Reifegrad. PdM bedeutet hohen Aufwand, von der initialen Planung bis hin zur Umsetzung und Realisierung von ersten Ergebnissen. PdM „passiert“ nicht von heute auf morgen. Es muss ein Business Case entwickelt werden, die zu erfassenden Daten müssen definiert werden, in vielen Fällen müssen Sensoren nachgerüstet werden (Retrofitting) und der Aufbau belastbarer Datenreihen bedarf, je nach Fehlerbild, mehrerer Jahre. Explorative Datenanalysen müssen durchgeführt, Modelle entwickelt und in die tägliche Praxis implementiert werden.

Unternehmen mit hohem Reifegrad profitieren – wie die Ergebnisse zeigen – von der Aufbauarbeit und den Anstrengungen der vergangenen Jahre. 73% beurteilen die Ergebnisse der PdM-Initiative als positiv, 27% immerhin noch neutral und negative Beurteilungen gibt es keine.

Anders sieht es bei Unternehmen mit mittlerem und niedrigem Reifegrad aus. Bei Unternehmen mit mittlerem Reifegrad überwiegen mit 68% noch die positiven und neutralen Bewertungen, aber es gibt mit 14% auch schon die ersten negativen Beurteilungen und 18% haben sich anscheinend noch nicht entschieden, wie das PdM-Programm zu beurteilen ist.

Die Unternehmen mit niedrigem Reifegrad enthalten sich mit 50% der Stimmen, wie zufrieden sie mit den Ergebnissen sind und auch der höchste Teil der negativen Beurteilungen mit 17% findet sich in diesem Segment.

Unternehmen mit niedrigem und mittlerem Reifegrad scheinen noch keine überzeugenden Resultate erzielt zu haben und es wird wohl externer Unterstützung bedürfen, um entsprechendes Know-How aufzubauen und (mit entsprechender Vorlaufzeit) positive Ergebnisse zu erzielen.

HINDERNISSE BEI DER EINFÜHRUNG VON PREDICTIVE MAINTENANCE




Abbildung 11: Hindernisse bei der Einführung von PdM

Unternehmen mit hohem Reifegrad sind in Bezug auf die Hindernisse in ihrer Bewertung weitgehend „neutral“. Es scheint, dass die größten Hürden bereits genommen wurden und die PdM-Programme sich in der täglichen Praxis bewähren.

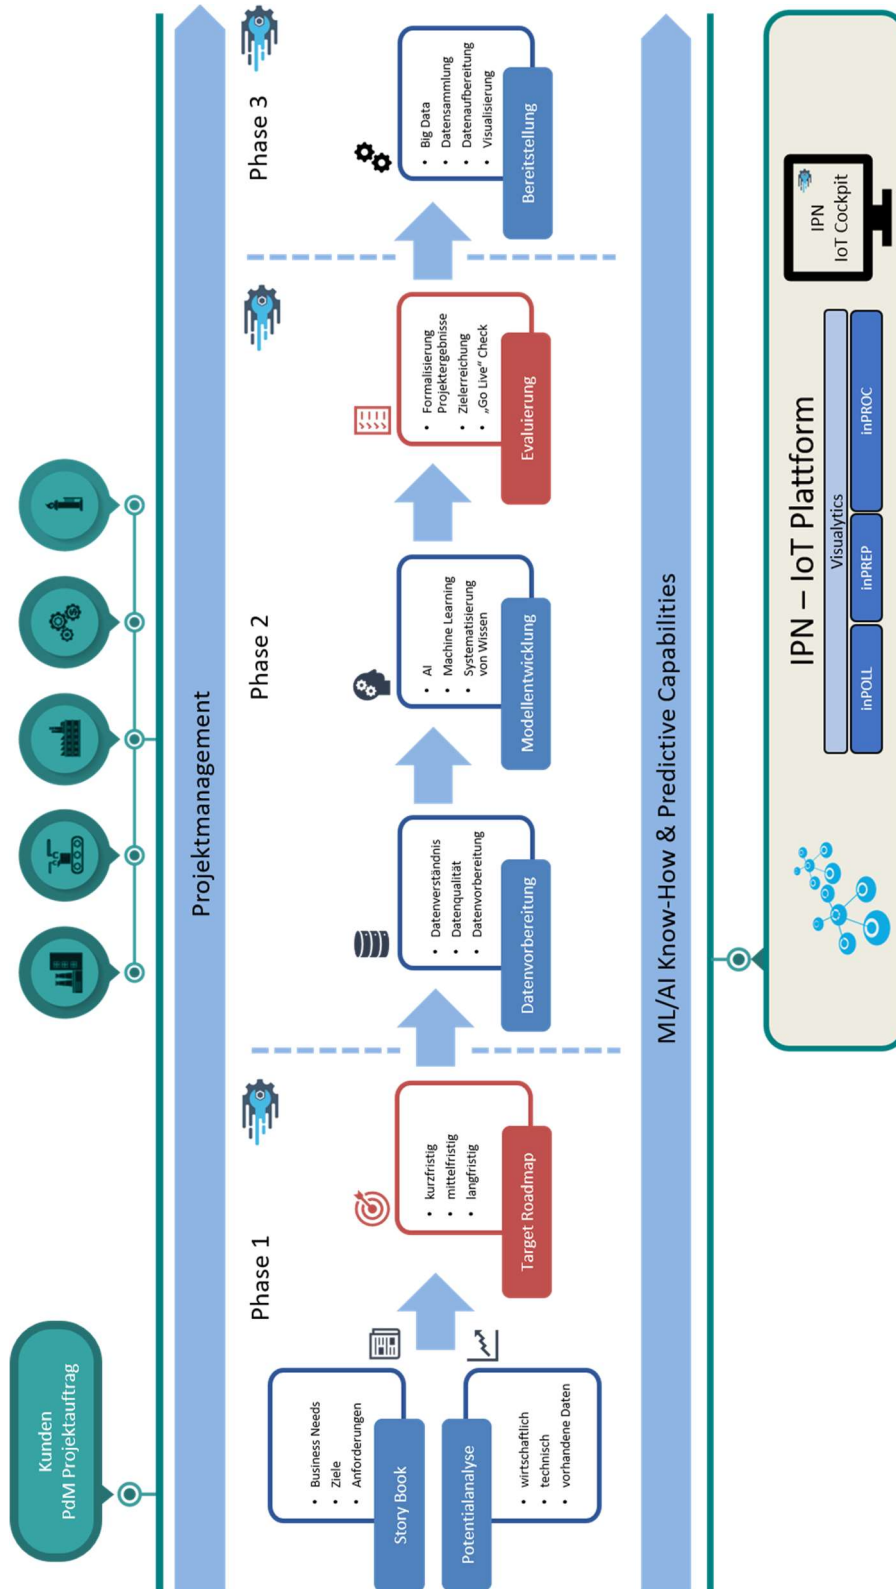
Speziell Unternehmen mit niedrigem Reifegrad beklagen den Mangel an Know-How in der Herangehensweise und begrenzte technische Ressourcen für die Umsetzung von PdM. Zudem stellen die Datenerfassung und die Weiterverarbeitung der Daten für diese Unternehmen noch ein Problem dar.

„Mangelnde Unterstützung durch das Management“ und der „Hemmschuh“ Unternehmenskultur werden durchgehend neutral bewertet. Die „Digitalisierung“ scheint ihren Weg in die Unternehmen und zum Management gefunden zu haben, so dass diese Faktoren keine Hindernisse darstellen.

Stellräder für ein erfolgreiches PdM-Projekt



IPN Vorgehensmodell für eine erfolgreiche PdM-Einführung



FÜHREN SIE IHR PREDICTIVE MAINTENANCE PROJEKT ZUM ERFOLG

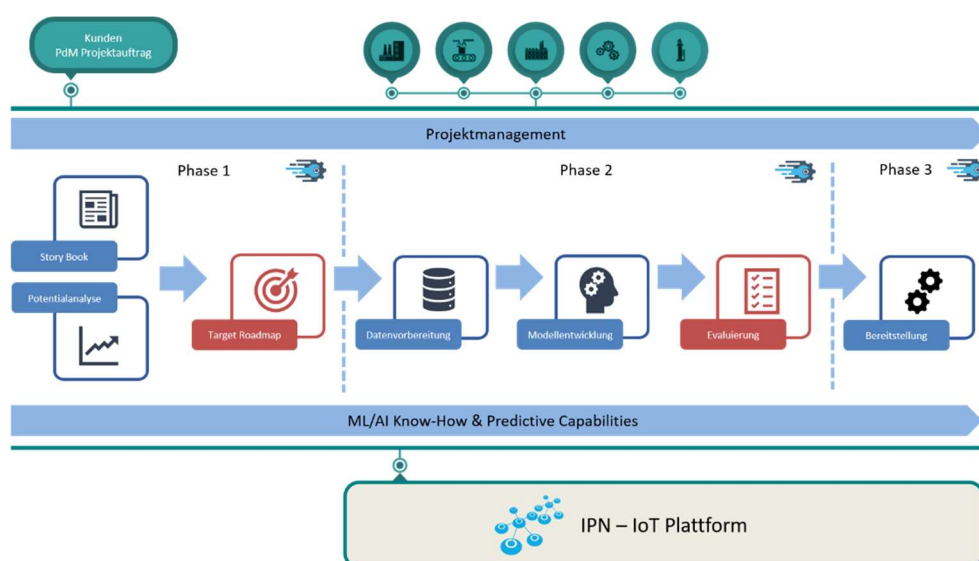
Wir haben gesehen, dass sich fast jedes Unternehmen bereits mit Predictive Maintenance beschäftigt. Während die Einführung einer IoT-Plattform für Predictive Maintenance von zentraler Bedeutung sein kann, ist der Umfang der Implementierung jedoch weit größer. Unternehmen müssen auch die organisatorische Dimension beachten, die mit einer erfolgreichen Einführung von PdM einhergeht.

Im Folgenden wird das von IPN entwickelte Prozessmodell vorgestellt, das auf Basis mehrerer, bereits erfolgreich umgesetzter PdM-Projekte, entwickelt wurde. Das Modell beinhaltet alle wesentlichen Aspekte, die bei der Implementierung beachtet werden müssen. Die Anwendung von Methoden der AI hat einen großen Stellenwert in diesem Vorgehensmodell, verzichtet aber auf den ganzen „Hype“ und „Buzz Words“, die in jüngster Zeit rund um die „Digitalisierung“ entstanden sind.

Das Ziel von AI oder deren bedeutendstem Teilgebiet „Machine Learning“ besteht nicht darin, ein künstliches Gehirn zu schaffen, sondern uns dabei zu unterstützen, die riesigen Datenmengen („Big Data“) zu verstehen. Dazu stellt Machine Learning eine Reihe von Algorithmen bereit, die diese Daten in verwertbares Wissen umwandeln.

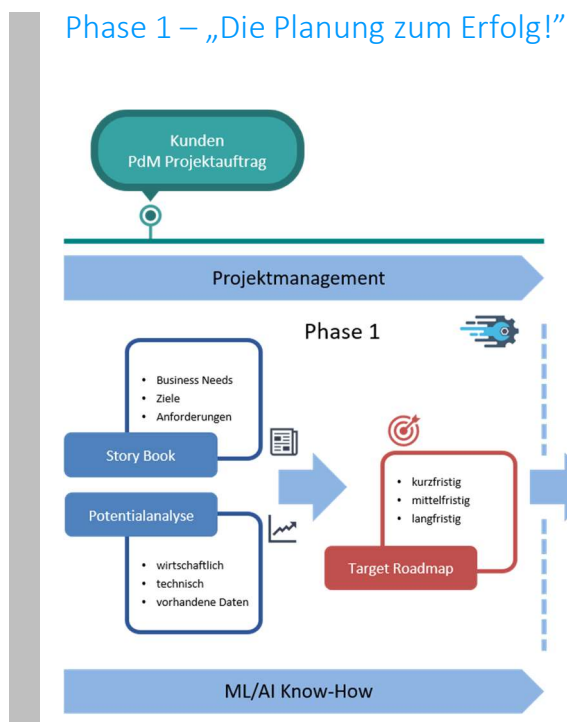
Machine Learning ist dann am erfolgreichsten, wenn es das Wissen der Fachexperten ergänzt, nicht aber versucht es zu ersetzen.

Das IPN Vorgehensmodell



Die Umsetzung eines PdM-Projektes erfolgt in 3 Phasen und beinhaltet 2 Milestones, in denen die notwendigen organisatorischen, datentechnischen und „AI-spezifischen“ Voraussetzungen für die Einführung von PdM geschaffen und evaluiert werden.

Flankiert wird das Modell durch ein maßgeschneidertes Projektmanagement und dem Aufbau von Know-How im Bereich von AI und Entwicklung der „Predictive Capabilities“.



1.1 PdM Story Book

Bei IPN steht die Entwicklung des „PdM Story Books“ am Anfang eines PdM-Projekts. Das Story Book wird in interaktiven Workshops erarbeitet und beinhaltet folgende Themenblöcke:

- Formulierung der Geschäftsanforderungen („Business Needs“) an PdM;
- Definition der Zielsetzungen, die mit PdM verfolgt werden;
- Identifikation der für die Zielerreichung zu schaffenden finanziellen, organisatorischen, technischen, rechtlichen und „intellektuellen“ Voraussetzungen.

Bei der Entwicklung des Story Books geht es nicht so sehr um die Ausarbeitung konkreter Details, sondern um die Identifikation aller für das Projekt wichtigen Parameter. In einer Art „Stakeholder-Analyse“ sollen die Rahmenbedingungen für die Nutzung von PdM analysiert werden. Damit stellen wir eine möglichst frühe Identifikation von wichtigen Personen(-gruppen), rechtlichen

Rahmenbedingungen, Kunden- und Lieferanteninteressen, betroffenen Unternehmensbereichen, Auswirkungen auf die technische Infrastruktur, Prozesse etc. sicher.

IPN rechnet mit circa drei Tagen Aufwand pro Business Unit (Unternehmensbereich) für die Abhaltung der Workshops, in denen speziell der „Strategische Aspekt“ von PdM beleuchtet wird. Weitere zwei Tage müssen für die Auswertung und Ergebnisaufbereitung der Workshop-Resultate angesetzt werden.

Den formalen Abschluss dieser Phase bilden die Ziele-, Anforderungs- und Bereichsmatrix. Diese Dokumente enthalten eine detaillierte Dokumentation der mit PdM verfolgten Ziele, der damit verbundenen Anforderungen und der davon betroffenen Unternehmensbereiche.

1.2 PdM Potentialanalyse

Die Potentialanalyse gliedert sich in drei Teile:

1. wirtschaftliche Potentiale
2. technische Potentiale
3. Potential der bereits vorhandenen Daten

Durch die Potentialanalyse kann festgestellt werden, welche wirtschaftlichen und technischen Potentiale im konkreten Kunden-Setup kurz-, mittel- und langfristig mit PdM realisiert werden können. Die Datenpotentialanalyse dient der Erfassung und dem Abgleich der bereits vorhandenen Daten (IST-Daten), mit den für die Realisierung des Projektes notwendigen SOLL-Daten. Dieser SOLL-IST-Vergleich ermöglicht eine realistische Einschätzung des Zeithorizonts für die Realisierung der PdM-Potentiale.

1.2.1 Durchführung wirtschaftliche Potentialanalyse

Zielsetzung ist die nach betriebswirtschaftlichen Kriterien durchgeführte Identifikation und Selektion der für das PdM-Projekt am besten geeigneten Maschinen und Anlagen.

Auch wenn PdM weit über den reinen Kostenaspekt hinausgeht, stehen Kosteneinsparungspotentiale meist im zentralen Fokus solcher Analysen. Die mit der Instandhaltung verbundenen Kosten sind in den meisten Fällen gut dokumentiert aus dem betrieblichen Rechnungswesen verfügbar.

Die durch PdM erschließbaren „Zukunftspotentiale“ (Erhöhung des Know-Hows über die eigenen Produkte, Ideen für neue Produkte und Services etc.) werden am Anfang von PdM-Projekten meist noch außer Acht gelassen, aber auf das strategische Potential der Maschinen und Anlagen darf nicht vergessen werden. Hier geht es speziell um „Anlagenkritikalität“, d.h. die Wichtigkeit des Assets für die betriebliche Leistungserstellung. Kritische Assets sind nicht zwingend mit den höchsten Kostenpotentialen verbunden, sollten aber aufgrund ihrer strategischen Wichtigkeit in das PdM-Programm mit eingebunden werden.

Die wirtschaftliche Potentialanalyse kann in den meisten Fällen von den Unternehmen in Eigenregie durchgeführt werden. IPN bietet dazu ein entsprechendes Template an und kann gegebenenfalls auch unterstützend mitwirken.

Das Ergebnis dieser Phase ist die „**Asset Value Ranking List**“. Da die Erfassung der Instandhaltungskosten meist auf Systemkomponentenebene erfolgt, stellt diese Liste in vielen Fällen auch schon die grobe Struktur für die nachfolgende technische Potentialanalyse zur Verfügung.

1.2.2 Durchführung technische Potentialanalyse

Nach der unter wirtschaftlichen und strategischen Gesichtspunkten durchgeführten Anlagenselektion, erfolgt die „**Fehler-Ursachen-Effektanalyse**“. In einer durch IPN moderierten technischen Expertenrunde werden bekannte Fehler hinsichtlich ihrer Ursachen und Auswirkungen und die Möglichkeiten der „sensorischen“ Fehlererkennung analysiert. Ziel ist die Erhebung der für die Fehlererkennung notwendigen Daten und die Definition der dafür benötigten Sensoren.

Nur in wenigen Fällen ist es möglich, einen Fehler direkt zu erfassen, womit die Herausforderung in dieser Phase darin besteht, einen „**Signalverbund**“ zu definieren, der unter Zuhilfenahme entsprechender Analysemethoden und Machine-Learning-Algorithmen zuverlässige Prognosen über sich abzeichnende Störungen liefert. Die „datenbasierte“ Herangehensweise an diese Problemstellung erfolgt nach einer von IPN entwickelten Methodik und wird in Form von Workshops durchgeführt.

Das Ergebnis dieser Phase ist die Feststellung der technischen Möglichkeiten und der Machbarkeit der Fehlerdetektion und Datenerfassung an den ausgewählten Maschinen und Anlagen und der dafür benötigten Daten (SOLL-Daten).

Der Aufwand in dieser Phase hängt von der Komplexität der zu analysierenden Systeme ab und erfordert auch eine Einführung in die Methodik, die in den Workshops zur Anwendung kommt.

IPN rechnet mit circa zehn bis fünfzehn Tagen Aufwand (je nach Anlagenkomplexität) für die Abhaltung der Workshops, in denen speziell das „technische Potenzial“ von PdM beleuchtet wird. Weitere drei bis fünf Tage müssen für die Auswertung und Ergebnisaufbereitung der Workshop-Resultate angesetzt werden.

1.2.3 Potential der bereits vorhandenen Daten

Der Zeithorizont für die Realisierung der für PdM definierten Unternehmensziele ist unter anderem von der Verfügbarkeit der dafür benötigten Daten abhängig. Zur Überprüfung der Datenverfügbarkeit, bzw. des Bedarfs für weitere (Daten-)Messpunkte, wird eine Erhebung der bereits bestehenden Messpunkte und Datenarchive durchgeführt und in einem Datenkatalog dokumentiert.

In diesem Datenkatalog werden die bereits vorhandenen Daten, Datenquellen und Systeme angeführt, um so einen Abgleich der SOLL- mit den IST-Daten zu ermöglichen. Durch diesen SOLL-IST

Vergleich wird ersichtlich, mit welchem Zeithorizont die PdM-Aktivitäten zu planen sind. Für nicht, bzw. in zu geringer Auflösung vorhandene SOLL-Daten muss erst die Infrastruktur zur Datenerzeugung und -sammlung geschaffen und entsprechend Zeit eingeplant werden, damit belastbare Zeitreihen für weitere Analysen und die Modellentwicklung zur Verfügung stehen.

IPN rechnet mit 10 Tagen Aufwand (je nach Datenverfügbarkeit) für die Sichtung und Bewertung der Daten, sowie die Erstellung des Datenkatalogs.

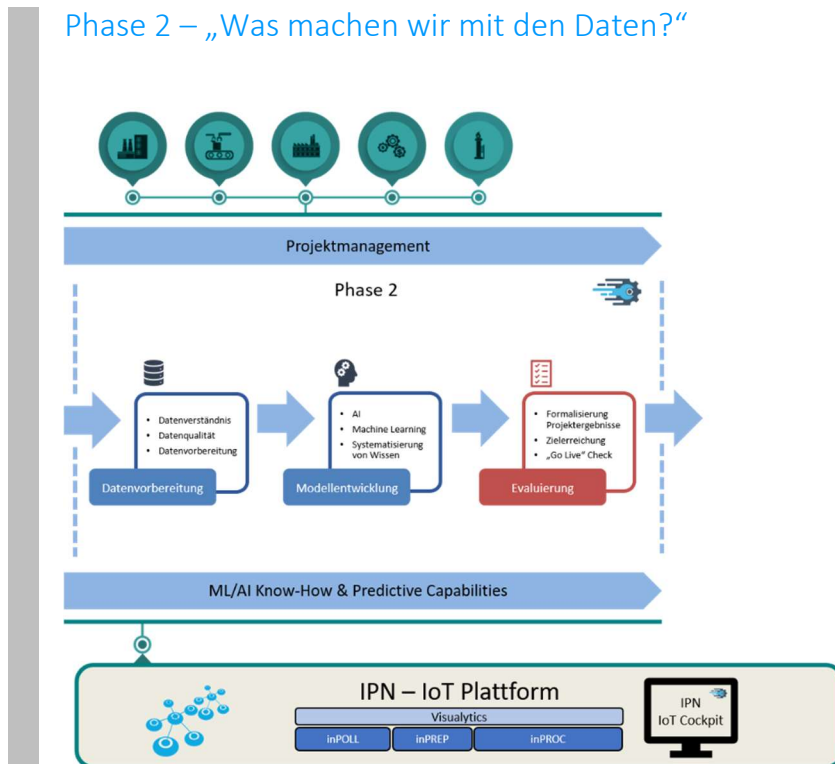
1.3. Milestone - PdM Target Roadmap

Die PdM Target Roadmap stellt den ersten wichtigen „Meilenstein“ für ein PdM-Projekt dar. In der Target Roadmap werden die Ergebnisse aus der wirtschaftlichen und technischen Potentialanalyse zusammengeführt, mit den Ergebnissen der „Datenpotential-Analyse“ abgeglichen und entsprechend den Zielen des PdM Story Books priorisiert.

Unter Berücksichtigung der Datenverfügbarkeit (IST-Daten), der für die Erreichung der definierten PdM-Ziele benötigten Daten (SOLL-Daten) und dem mit der Erhebung der SOLL-Daten verbundenen Aufwand, wird in der Target Roadmap eine abschließende Bewertung der „**Prognosepotentiale**“ und die Darstellung des PdM-Projekts in „Szenarien“ vorgenommen:

- *kurzfristiges Szenario* – mit bestehenden Daten und Messpunkten realisierbare „Prognosepotentiale“;
- *mittelfristiges Szenario* – mit bestehenden Daten ergänzt durch Versuchsdaten realisierbare „Prognosepotentiale“;
- *langfristiges Szenario* – unter Hinzunahme neuer Messpunkte realisierbare „Prognosepotentiale“;
- *nicht umsetzbar* – Aufwand für neue Messpunkte ist zu groß bzw. technisch nicht realisierbar.

Phase 2 – „Was machen wir mit den Daten?“



2.1. Datenprüfung und -vorbereitung

Mit den bereits vorhandenen Daten kann begonnen werden, die laut Target Roadmap definierten „kurzfristigen“ PdM-Potentiale zu realisieren. Die Datenprüfungs- und Vorbereitungsphase ist erfahrungsgemäß mit dem größten Aufwand verbunden und kann in drei Schritte unterteilt werden:

1. Im ersten Schritt „Datenverständnis“ erfolgt die detaillierte, anforderungsspezifische Untersuchung der für das PdM-Projekt bereits verfügbaren Daten. Dieser Schritt ist überaus wichtig, um unerwartete Probleme im nächsten Schritt – „Datenvorbereitung“ – zu vermeiden. Zur Phase des Datenverständnisses gehört der Zugriff auf die Daten und deren Untersuchung mithilfe von Tabellen, Grafiken und statistischen Methoden, die mit dem IPN-Projekttool „Visualytics“ organisiert werden können.
2. Im zweiten Schritt erfolgt eine „Datenqualitätsprüfung“. In den seltensten Fällen sind Daten perfekt. Tatsächlich weisen die meisten Daten Kodierungsfehler, fehlende Werte oder andere Arten von Inkonsistenzen auf, die eine Analyse teilweise kompliziert oder unmöglich machen. Um potenzielle Probleme zu vermeiden, muss vor der Modellbildung eine gründliche Qualitätsanalyse durchgeführt werden. Auch hier kann IPN Visualytics wertvolle Dienste leisten, bzw. stehen teilautomatisierte Routinen zur Verfügung, mit denen die IPN Data Scientists rasch zu Ergebnissen in der Qualitätsprüfung kommen.
3. Der dritte und letzte Schritt – „Datenvorbereitung“ – ist einer der wichtigsten und sehr oft zeitaufwendigsten Aspekte des Data Mining. Ziel ist die Vorbereitung der Daten für die nachfolgende Modellentwicklung. Abhängig von den Zielen umfasst die Datenvorbereitung in der Regel das Verbinden von Daten-Sets aus unterschiedlichen Quellen, die Aggregation von

Datensätzen, die Ableitung neuer Attribute („Feature Engineering“), das Entfernen oder Ersetzen leerer oder fehlender Werte („Imputation“) und die Aufteilung in Training- und Testdaten-Sets.

2.2. Modellentwicklung

Die Modellbildung wird in der Regel in mehreren Schritten durchgeführt. In den meisten Fällen verwenden die IPN Data Scientists mehr als ein Verfahren (Machine Learning Algorithmus), um das Problem aus mehreren Richtungen in Angriff zu nehmen.

KISS – „Keep it Simple and Smart“ ist der Zugang von IPN, wenn es um den Einsatz von Machine Learning Algorithmen in PdM-Projekten geht. IPN vertritt die Philosophie, dass „einfache“ (deswegen aber nicht notwendigerweise weniger effiziente) Algorithmen für den PdM-Einsatz besser geeignet sind als komplexe „Black Box Modelle“.

Bei einfachen Algorithmen sind der Weg zur Entscheidungsfindung und die Resultate des Modells („Predictions“) nachvollziehbar und interpretierbar, d.h. es ist ersichtlich, welche Eingangsdaten (z.B. Motorstrom, Temperatur, Drehzahl etc.) den größten Einfluss auf das Vorhersageergebnis haben.

In den meisten Fällen haben die Projektbeteiligten keine oder nur sehr wenig Erfahrung mit den Prozessen und Methoden von Künstlicher Intelligenz. Wenn man „Simple und Smart“ vorgeht, stellt man auch sicher, dass Skepsis und Unsicherheit gegenüber AI abgebaut werden und setzt so einen wichtigen Schritt in die Richtung, dass „Digitalisierung“ als Chance und interessantes Betätigungsfeld wahrgenommen wird.

Die Verwendung von einfachen und interpretierbaren Algorithmen erfolgt aber auch noch unter einem anderen, ganz wesentlichen Aspekt:

„Systematisierung und Dokumentation des vorhandenen Wissens über die Maschinen und Anlagen.“

Oft ist großes, über viele Jahre aufgebautes „Erfahrungswissen“ nur in den Köpfen der Mitarbeiter vorhanden. Unternehmen sollten daher auch diesen „**Dokumentationsaspekt**“ in ihre Überlegungen miteinbeziehen, wenn es um die Auswahl von Machine Learning Algorithmen geht. Zum Beispiel können bei einem Entscheidungsbaum (Decision Tree) die Regeln für die Entscheidungsfindung angezeigt werden und stehen damit für weitere Interpretation, Diskussion und Dokumentation zur Verfügung.

Sollten die jeweilige Situation, die Problemstellung und die Datenstruktur dafür sprechen, können durch die Spezialisten von IPN auch komplexe Algorithmen, wie z.B. Random Forest, Boosted Trees, Support Vector Machines, Neuronale Netzwerke etc. umgesetzt werden.

2.3. Milestone - Evaluierung

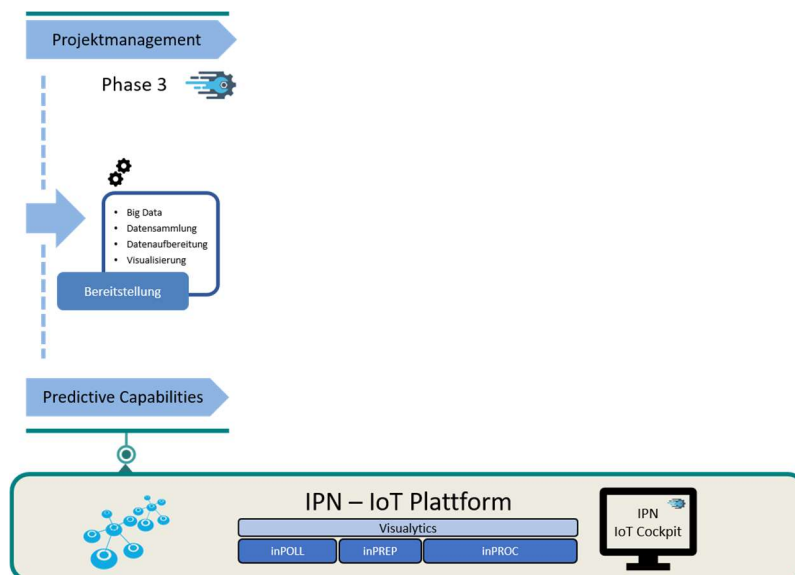
Dieser Meilenstein bildet den formalen Abschluss der vorangegangenen Phasen. Es erfolgt die Überprüfung der am Beginn des Projektes definierten Ziele anhand der erzielten Resultate und ob alle Voraussetzungen für ein „Go Live“ geschaffen wurden.

Typische Fragestellungen in der Evaluierungsphase sind:

- Sind die im Story Book enthaltenen Annahmen haltbar?
- Konnten die gesteckten Ziele erreicht werden?
- Wurden alle Voraussetzungen für ein „Go-Live“ geschaffen?
- Kann Machine Learning (AI) die erhofften Resultate liefern?
- Ist die Organisation fit für die Digitalisierung?
- Sind die für PdM notwendigen Skills im Unternehmen vorhanden?

Es erfolgt eine formalisierte Gesamtschau und wenn diese positiv ausfällt, kann mit der operationalen Umsetzung von PdM im täglichen Betrieb begonnen werden.

Phase 3 – „Welche Technologie benötigen wir?“



3.1. Bereitstellung

Konnte in den vorangegangenen Projektphasen in vielen Fällen noch nicht auf eine bestehende IoT-Infrastruktur zugegriffen werden, ist dieses Thema spätestens in der Bereitstellungsphase von zentraler Bedeutung. In den „Vorphasen“ werden die Daten meist „händisch“ zusammengefügt,

aufbereitet und die entsprechenden Algorithmen auf die Datenbasis angewendet. In der Bereitstellung wird es zwingend notwendig, dass die Prozesse automatisiert ablaufen. Datenannahme – Qualitätsprüfung – Aufbereitung – Transformation – Modellanwendung – Bereitstellung der Prognoseergebnisse – Veranlassung entsprechender Maßnahmen müssen in nahezu Echtzeit erfolgen.

IPN bietet für diesen Zweck eine aus den Anforderungen der Praxis entstandene, eigenentwickelte IoT-Plattform. Die IPN IoT-Plattform bietet folgende Features:

- Datensammlung und Zustandsüberwachung:
 - Automatisierte Sammlung, Aufbereitung und Verarbeitung von Prozessdaten in nahezu Echtzeit (Batch-Data, Streaming-Data);
 - Aufbau einer strukturierten, für detaillierte Analysen geeigneten Datenbasis;
 - Einfache Anwendung von Regeln und Modellen zur automatisierten Zustandsüberwachung von Anlagen.
- Prognose von Anlagenzustand & Produktqualität
 - Machine Learning Toolbox, für die Entwicklung und Umsetzung spezifischer Prognosealgorithmen;
 - Zukünftiger Anlagenzustand und zukünftig benötigte Wartungstätigkeiten;
 - Prognose der Produktqualität sowie benötigte Parameteränderungen zur Qualitätsoptimierung;
 - Identifikation der produkt-/betriebs-/energieoptimalen Produktionsparameter.
- Intuitive Visualisierung
 - Visualisierung der gesammelten Daten zur Analyse von Zusammenhängen zwischen Parametern und Ereignissen;
 - Unterstützung bei der Ursachenanalyse durch eine intelligente Vorselektion relevanter Einflussgrößen;
 - Automatisierte Bewertung und kontinuierliches Reporting der Datenqualität.

Die Bereitstellung ist keineswegs trivial und kann nicht auf eine Technologieauswahl beschränkt werden. Ein PdM-Projekt besteht aus einer fachlichen (Prozesse) und technologischen (IoT-Plattform) Ebene, die ineinandergreifen. Die fachliche Ebene kann für sich alleine stehen, die technologische nicht. Es sollte daher besser zweimal überlegt werden, ob eine solche Zweiteilung von PdM-Projekten – wie in der Praxis oft erlebt – vorgenommen wird. Wenn schon zweigeteilt, dann nur zeitlich. Getreu der Managementweisheit „Structure follows Strategy“, sollte mit der Auswahl der Technologieplattform erst dann gestartet werden, wenn alle Prozessanforderungen definiert wurden.

* * * * *

STUDIENDATEN

Durchführungszeitraum der Studie: vom 04.09.2018 – 28.09.2018

Instrument: Computer Assisted Web Interviews / Online-Befragung


Sprache: Kundenbefragung in deutscher Sprache

Studienteilnehmer: Personen, deren e-Mail-Adressen dem Auftraggeber vorliegen


Umfang: 31 Fragen

Studienteilnehmer: 51 Teilnehmer aus österreichischen Unternehmen haben die Studie beantwortet. 49 Teilnehmer, die eine Einschätzung des Reifegrads abgegeben haben, wurden in die Auswertung mit einbezogen.


Teilnehmer nach Bundesland



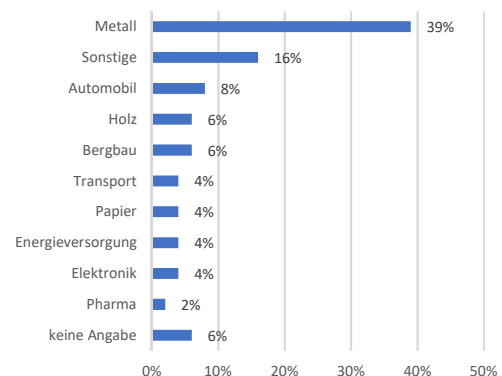
Umsatzgröße der teilnehmenden Unternehmen



Mitarbeiteranzahl der teilnehmenden Unternehmen



Industriesektor der teilnehmenden Unternehmen





LERNEN SIE DIE SPRACHE IHRER MASCHINEN ZU VERSTEHEN und wie Sie Predictive Maintenance ERFOLGREICH umsetzen.

Die Spezialisten von IPN – Intelligent Predictive Networks haben sich zum Ziel gesetzt, die PdM-Programme von Unternehmen zum Erfolg zu führen.

Nutzen Sie unseren eintägigen Workshop und werfen Sie einen Blick hinter die Kulissen von Predictive Maintenance und Machine Learning. Sie erfahren wie Sie IHR PdM-Projekt strukturieren, welche Prozessschritte durchlaufen werden und welche Inhalte und Anforderungen damit verbunden sind. Und das vollkommen befreit von dem mit der Digitalisierung verbundenen „Hype“ und „Buzz Words“.

Interessiert?

Dann senden Sie ein Mail an Dr. Alexander Wimmer: alexander.wimmer@predictive.at

Der Autor

Mag. Dr. Alexander Wimmer, MBA ist als Projektmanager bei IPN – Intelligent Predictive Networks tätig.

Mehr erfahren Sie unter at.linkedin.com/in/dr-alexander-wimmer-a60b9529

Mitautoren

DI Robin Kühnast ist Geschäftsführer der ÖVIA und wissenschaftlicher Mitarbeiter am Lehrstuhl WBW der Montanuniversität Leoben.

DI Robert Bernerstätter ist wissenschaftlicher Mitarbeiter am Lehrstuhl WBW der Montanuniversität Leoben.

Über IPN – Intelligent Predictive Networks GmbH

IPN - Intelligent Predictive Networks GmbH (www.predictive.at) ist ein Unternehmen im Bereich Data Mining für Kunden in der Industrie. Unsere Mitarbeiter sind Experten für die Analyse und Vorhersage von Maschinenzuständen (Predictive Maintenance), Prozessstabilität und Produktqualität. Dazu kommen modernste Technologien aus den Bereichen Big Data, IoT (Internet of Things) und maschinellem Lernen / künstlicher Intelligenz zur Anwendung.

Die von uns entwickelten Softwarelösungen und statistischen Modelle ermöglichen die Vorhersage von Maschinenversagen und Prozessqualität und ermöglichen dadurch eine kostengünstigere und effizientere Produktion. Neben der Produktentwicklung setzen wir Projekte im Data Mining Umfeld im In- und Ausland um.

Mehr erfahren Sie unter www.predictive.at

Über ÖVIA - Österreichische Vereinigung für Instandhaltung und Anlagenwirtschaft

Im Mai 1989 wurde die Gründung der "Österreichischen Vereinigung für Instandhaltung und Anlagenwirtschaft" (ÖVIA) beschlossen, mit dem Ziel alle Aktivitäten auf dem Gebiet der Instandhaltung zwischen technisch-wissenschaftlichen Vereinen und der Industrie zu koordinieren, Kontakte mit internationalen Institutionen zu pflegen und durch branchenspezifische Arbeitsgruppen das Fachwissen auf diesem Gebiet zu fördern.

Mehr erfahren Sie unter www.oevia.at