

# VOORSPELLEND ONDERHOUD IN ZES STAPPEN

Predictive maintenance: iedereen spreekt erover en lijkt te weten hoe het moet. Maar hoe is het in de praktijk te implementeren? Over assets, statistiek en algoritmen, en een helder zes-stappenplan om voorspellend onderhoud in te voeren.


Om voorspellend onderhoud in te kunnen voeren is big data nodig. Allereerst moet een productie-systeem daarom worden voorzien van sensoren, die gegevens over de operationele prestaties monitoren en verzamelen. Veel bedrijven beschikken al over grote hoeveelheden gegevens die worden gebruikt om de processen te sturen. Deze gegevens zijn vaak ook al jarenlang bewaard en kunnen dus actief gebruikt worden om de resterende

levensduur van assets te voorspellen. Doorgaans omvatten gegevens voor voorspellend onderhoud een tijdstempel, een reeks sensormetingen verzameld op hetzelfde moment met tijdstempel en apparaat-identificaties.

## TEKENEN VAN VERVAL

De pf-curve in de figuur rechts laat zien dat een asset op het tijdstip  $t = 0$  een bepaalde prestatie

levert en dat deze prestatie afneemt naarmate de tijd verstrijkt. Dit kan te wijten zijn aan gebruik, veroudering, slijtage, omgeving of andere factoren. De figuur laat ook zien welke anomaliecategorieën tijdens de levensduur van een asset uit de verschillende soorten gegevens opgesteld kunnen worden. Trillingsmetingen en olie-analyse geven een eerste indicatie van degradatie. Daarna zal de asset op een gegeven moment hogere dan



De pf-curve toont afnemende prestaties van de asset in de tijd en anomaliecategorieën.

normale temperatuurmetingen vertonen. Het is vaak moeilijk vast te stellen wanneer een faalmodus precies is begonnen. Maar het is wel mogelijk om op zoek te gaan naar tekenen van verval, zodat

het probleem aangepakt kan worden voordat de asset faalt. Daarom is het belangrijk om het gedrag van de sensormetingen voor elke storingsmodus van elk asset te begrijpen.

## ALGORITMEN

Voor voorspellend onderhoud werken classificatie- en clusteringsalgoritmen het best. Met deze algoritmen kunnen historische gegevens (assetgedrag) gecategoriseerd worden in vooraf gedefinieerde classificatie-/clustergroepen. Dan levert

## Categorisering (labeling) van gegevens is een belangrijk onderdeel van predictief onderhoud


de combinatie van een verhoogde temperatuur en een licht gestegen trillingsmeting bijvoorbeeld een categorielabel op zoals 'een week voor falen'. Deze categorisering (labeling) van gegevens is een belangrijk onderdeel van predictief onderhoud. De labels worden bepaald voor elk geval apart (elke combinatie van asset en faalmodus) en variëren van een binair label (goede vs. slechte prestaties)



Onderhoudswerkzaamheden door een Stork-medewerker. Voorspellend onderhoud optimaliseert de technische beschikbaarheid van een asset.

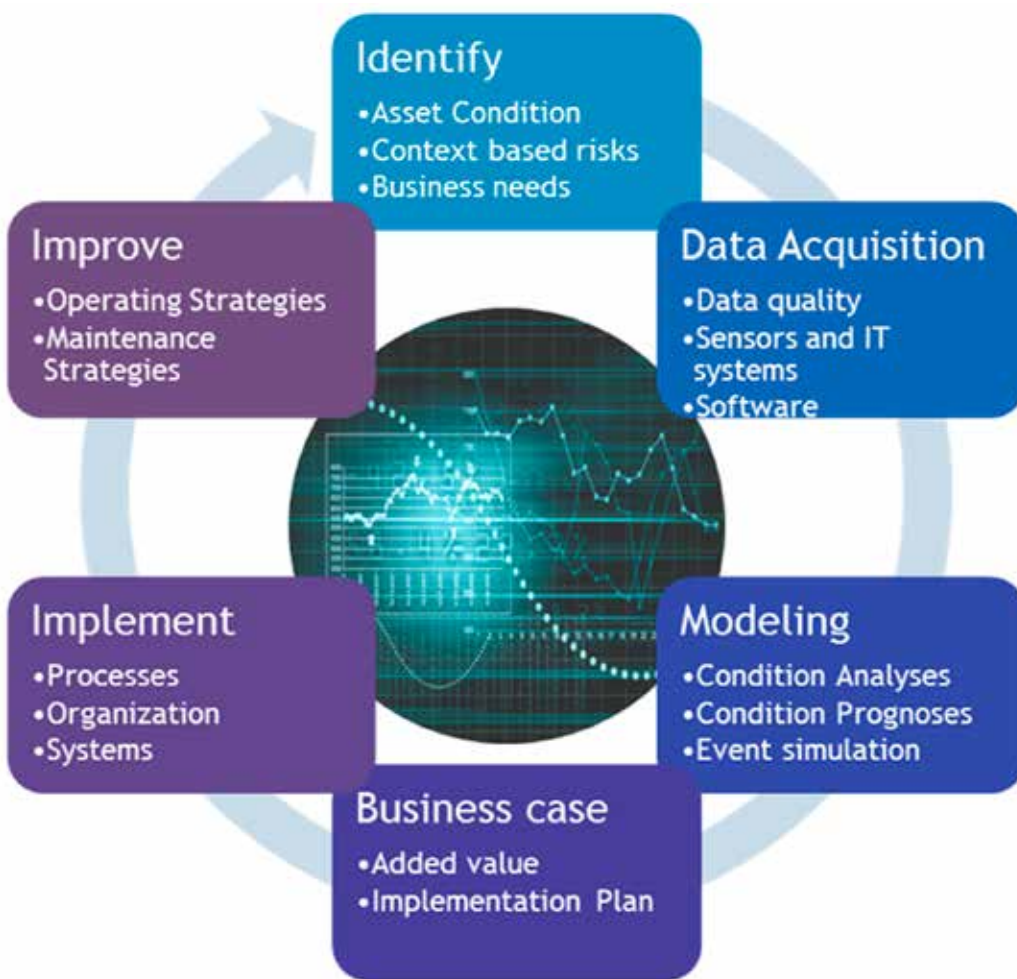
## Waarom voorspellend onderhoud?

Onderhoud werd traditioneel uitgevoerd volgens een bewezen, op betrouwbaarheid gebaseerde onderhoudsmethode (RCM): een combinatie van reactief gebaseerd onderhoud (RBM), op tijd gebaseerd onderhoud (TBM) en conditie gebaseerd onderhoud (CBM). Nadeel daarvan was dat deze uitgaat van de gemiddelde tijd tussen falen (MTBF) en de veronderstelling dat het faalpatroon in de loop van de tijd toeneemt. Maar de MTBF is een gemiddelde, dus de werkelijke tijd tussen falen varieert en dit betekent dat een onderdeel vaker kan falen dan 'berekend', met als gevolg downtime, minder opbrengsten en/of onnodig vervangen onderdelen. Ook periodieke onderhoudsinspecties om degradatie te detecteren is geen wondermiddel. Het leidt tot meer manuren en soms zelfs een hogere werklast dan in een run-to-failure scenario. Aangezien slechts 18% van de fouten leeftijd-gerelateerd is en 82% een willekeurig faalpatroon heeft (NASA / US Navy, 2008), biedt RCM geen complete oplossing voor het optimaliseren van onderhoud. Voorspellend onderhoud wel. Voorspellend onderhoud optimaliseert de technische beschikbaarheid van een asset door onderhoudsparameters als frequentie en huidige onderhoudsstrategie te beïnvloeden. Methoden en technieken voor voorspellend onderhoud zijn gericht op het bepalen van de staat (gezondheid) van de assets en op de vraag wanneer onderhoud nodig is.



Alleen onderhoud plegen als uit de meetgegevens blijkt dat het nodig is.





Zes-stappenmodel voor het invoeren van voorspellend onderhoud.

tot een glijdende schaal (resterende gebruiksduur 30 dagen, 29 dagen, etc.). Algoritmen die voor classificatie kunnen worden gebruikt zijn bijvoorbeeld (lineaire) Support Vector Machine, Naïve

Bayes, KNeighbors en logistic regressie. Voor clustering zijn dit KMean, MeanShift en SpectralClustering. Welke algoritmen de beste fit opleveren, hangt af van de steekproefomvang, het gegevens-type (gelabeld, hoeveelheid of tekstgegevens) en diepgaande kennis van de faalwijzen van de asset.

## Fouten

Net als in de statistiek kunnen er zich bij voorspellend onderhoud ook 'fout positieve' en 'fout negatieve' resultaten voordoen. Een fout positieve bevinding is een asset dat niet werkt, terwijl de prestaties van de asset eigenlijk goed (gezond) zijn. Deze fout leidt tot onterecht onderhoud: er wordt iemand bij geroepen om de asset te controleren, terwijl die in goede staat verkeert, of erger nog, componenten van een goed functionerende asset worden vervangen. Een fout negatieve bevinding leidt tot hogere kosten: in dit geval treedt er een fout op die niet is voorspeld. Beide soorten fouten zijn te voorkomen door een verbeterproces in te richten (stap 6 van het model). Dit betekent dat algoritmen voortdurend nieuwe faalpatronen moeten leren totdat het algoritme slim genoeg is om 100% van de falende assets correct te voorspellen.

## ZES-STAPPENMODEL

Voor het kiezen van het juiste algoritme en de juiste implementatiemethode in de organisatie heeft Stork een zes-stappenmodel ontwikkeld. De eerste stap omvat het begrijpen van de functionaliteiten van de asset en de faalwijzen. Storingsgegevens worden uit het Computerized Maintenance Management System (CMMS-systeem) gehaald en procesgegevens worden uit het handboek van de fabrikant gehaald. Het resultaat is een diepgaand inzicht in de dominante faalmodus en de (financiële) impact ervan op de organisatie.

Stap twee is het selecteren van historische gegevens die gegevensstromen c.q. patronen bevatten die te labelen zijn als 'goede prestaties' of 'slechte prestaties'. Omdat algoritmen alleen patronen kunnen leren die al in de gegevens aanwezig zijn, moet de doel-set groot genoeg zijn om deze patronen te bevatten, maar ook beknopt genoeg zijn om binnen een redelijk tijdsbestek te worden gevonden. De datasets zijn vaak opgeslagen in

verschillende databases die eerst geïntegreerd moeten worden. Ook de kwaliteit van de gegevens is belangrijk. Alle gegevenssets moeten dezelfde tijdstempel hebben om meerdere sensoren voor één voorspelling te kunnen gebruiken. Vervolgens wordt voor ontbrekende gegevens interpolatie toegepast en worden ruisgegevens verwijderd.

## MODELLEREN EN BUSINESSCASE

De derde stap (modellering) omvat het extraheren van patronen uit de gegevens. Hiervoor worden geschikte (wiskundige) algoritmen geselecteerd en toegepast om zo een model te ontwikkelen dat het patroon beschrijft. Deze stap gaat vaak gepaard met 'traditionele' statistische analyse, gegevensvisualisatie en simulatie van historische gegevens (ontwikkeling van demo-versie).

In de vierde stap wordt een businesscase ontwikkeld om de voordelen van het voorspellen van een faalmodus hard te maken. De kosten van het schrijven van een algoritme en van real-time monitoring worden afgezet tegen de financiële voordelen. Besparingen vallen te behalen in het voorkomen of minimaliseren van downtime en het optimaliseren van periodiek onderhoud. Andere voordelen zijn de kapitalisatie van kennis, verlenging van de levensduur van assets, en arbo- en milieuverbeteringen. Deze 'andere' voordelen zijn niet altijd aanwezig en als er wel sprake van is, zijn ze vaak moeilijk te kwantificeren.

## INVOEREN EN VERBETEREN

Als de businesscase een positief resultaat heeft, begint stap vijf, de implementatiefase. De acties die in de vorige fasen zijn gedefinieerd, kunnen nu uitgevoerd worden. De organisatie gebruikt dus de informatie uit het model om de onderhoudsintervallen en werkprocessen aan te passen. Stap zes is het sluiten van de verbetercyclus. In de operationele fase begint het algoritme zelflerend te worden omdat voortdurend extra foutpatronen aan het algoritme worden toegevoegd.

Omdat zo veel bedrijven inmiddels al zoveel data beschikbaar hebben en omdat het relatief eenvoudig is om complexe algoritmen te ontwikkelen, is het juist nu zaak om te investeren in het voorspellen van de gezondheid van assets. Het ontwikkelen van effectieve algoritmen voor voorspellend onderhoud kost weliswaar tijd en geld, maar de totale voordelen wegen ruimschoots op tegen de initiële investering. ●

*Enos Postma is consultant bij Stork Asset Management Technology. Hij adviseert klanten over hun assetmanagement vraagstukken. Hij is gespecialiseerd in het implementeren van verbeterprocessen en voorspellende onderhoudsoplossingen voor onderhoudsorganisaties.*