

Leren van het optimale onderhoudsmoment

Citation for published version (APA):

Drent, C., & Drent, M. (2023). Leren van het optimale onderhoudsmoment. *STAtOR*, 24(3-4), 12-16.

Document status and date:

Gepubliceerd: 01/12/2023

Document Version:

Uitgevers PDF, ook bekend als Version of Record

Please check the document version of this publication:

- A submitted manuscript is the version of the article upon submission and before peer-review. There can be important differences between the submitted version and the official published version of record. People interested in the research are advised to contact the author for the final version of the publication, or visit the DOI to the publisher's website.
- The final author version and the galley proof are versions of the publication after peer review.
- The final published version features the final layout of the paper including the volume, issue and page numbers.

[Link to publication](#)

General rights

Copyright and moral rights for the publications made accessible in the public portal are retained by the authors and/or other copyright owners and it is a condition of accessing publications that users recognise and abide by the legal requirements associated with these rights.

- Users may download and print one copy of any publication from the public portal for the purpose of private study or research.
- You may not further distribute the material or use it for any profit-making activity or commercial gain
- You may freely distribute the URL identifying the publication in the public portal.

If the publication is distributed under the terms of Article 25fa of the Dutch Copyright Act, indicated by the "Taverne" license above, please follow below link for the End User Agreement:


www.tue.nl/taverne

Take down policy

If you believe that this document breaches copyright please contact us at:

openaccess@tue.nl

providing details and we will investigate your claim.



Op de foto: Melvin (links) en Collin (rechts), met op het bord de Bellman equation.

Leren van het optimale onderhoudsmoment

Collin Drent en Melvin Drent

Kapitaalgoederen degraderen wanneer zij in gebruik zijn en zullen op een bepaald moment onderhoud vereisen om nog te kunnen voldoen aan de eisen die hun gebruikers stellen. De degradatieprocessen van zulke kapitaalgoederen hangen af van vele individuele covariaten en zijn daarom dus niet identiek; het optimale moment waarop je onderhoud zou moeten doen is dat dus ook niet. Gelukkig zijn machines in toenemende mate uitgerust met sensoren die allerlei data over de conditie van de machine genereren in real time. In dit artikel, dat gebaseerd is op Drent e.a. (2023), beschrijven we een methode om aan de hand van die data te leren wanneer het voor iedere specifieke machine optimaal is om onderhoud te plegen.

Introductie

Kapitaalgoederen – zoals de röntgenscanners van Philips of de chipmachines van ASML – zijn machines die een product of dienst leveren. Het is daarom van cruciaal belang dat zulke machines werken wanneer je ze gebruikt, en dat ze niet ongepland stil komen te staan. Dit ongepland stilstaan kan ontzettend veel geld kosten, vooral wanneer het te leveren product of dienst veel waarde heeft. Het meest schrijnende voorbeeld is de chipmachine van ASML waar de kosten van één uur ongeplande stilstand van een chipmachine kunnen oplopen tot 72 duizend euro. Het goede nieuws van deze ongeplande stilstand is dat bijna de helft veroorzaakt wordt door het falen van kritische componenten. Dit zijn componenten die cruciaal zijn voor het functioneren van de machine; als zo een component faalt, dan staat de machine stil. De implicatie hier van is dus dat we deze kritische componenten preventief kunnen vervangen vóórdat ze falen, om zo de ongeplan-



Figuur 1: De standaardmethode om optimale control limits te bepalen.

de stilstand te voorkomen. Echter, aangezien deze kritische componenten vaak zelf ook duur zijn, wil je ze niet te vaak preventief vervangen want dat leidt ook tot veel onnodige kosten. Er is dus een trade-off en de vraag is wanneer het optimale onderhoudsmoment is, waarbij je het risico dat je later vervangt dan vereist is, optimaal balanceert met het risico dat je eerder vervangt dan werkelijk nodig is. Componenten degraderen over tijd totdat zij een bepaalde grens bereiken en kapotgaan. Moderne kapitaalgoederen zijn in toenemende mate uitgerust met sensoren die in real time de degradatie kunnen meten. We kunnen dus dit onderhoudsmoment bepalen aan de hand van de degradatie van een component – dit wordt *condition-based maintenance* genoemd – waarbij preventief onderhoud gepleegd wordt zodra de degradatie boven een bepaalde *control limit* komt. De vraag is nu: wat is de optimale control limit gegeven de bovengeschetste trade-off?


De conventionele route naar optimale onderhoudsmomenten

Zowel in de praktijk als in de literatuur is de standaardmethode om de optimale control limit te bepalen een sequentiële procedure bestaande uit twee stappen (zie Figuur 1 voor een schematische illustratie).

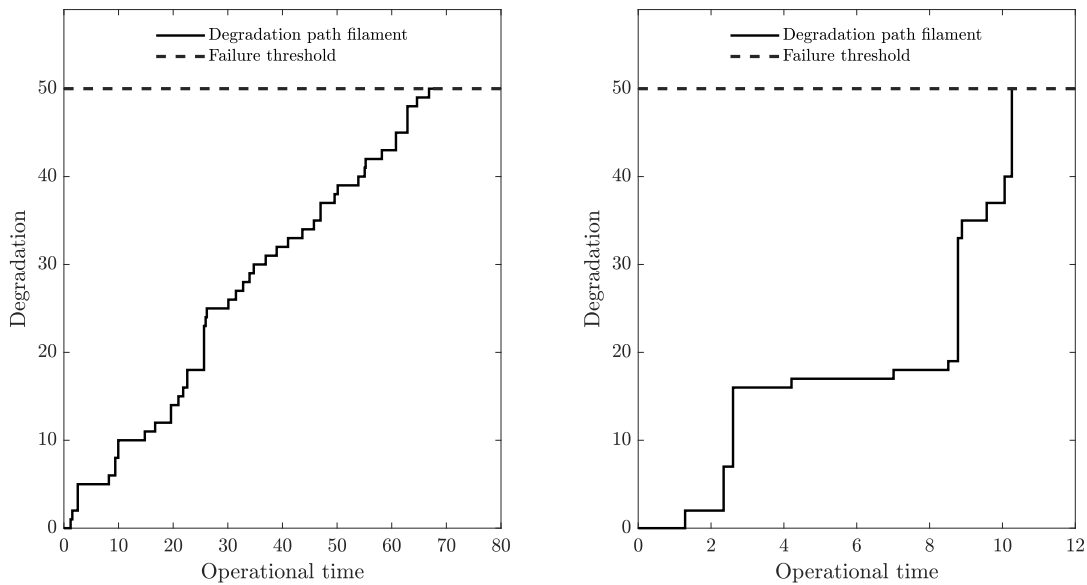
In de eerste stap schat men met behulp van een dataset van historische degradatiepaden van een bepaald type component, een statistisch model (meestal een stochastisch proces zoals een *Brownian motion* of een *compound Poisson process*) inclusief de relevante parameters dat het degradatieproces het meest accuraat modelleert. Vervolgens, in de tweede stap, optimaliseert men de control limit met als input het statistisch model en relevante kosten. Deze control limit wordt dan gebruikt om toekomstige onderhoudsmomenten van alle componenten van dat type te plannen. De cruciale aanname die ten grondslag ligt aan deze sequentiële methode is dat alle componenten van hetzelfde type altijd hetzelfde degradatiegedrag vertonen. Met andere

woorden: er wordt verondersteld dat componenten van hetzelfde type statistisch niet van elkaar te onderscheiden te zijn. Een direct gevolg hiervan is dat alle componenten dezelfde control limit zullen hebben.

Voor dit onderzoek hebben wij samengewerkt met Philips – een producent van onder andere medische apparatuur. Een van Philips' producten is een zogenaamd iXR systeem. Dit is een röntgenapparaat dat gebruikt kan worden tijdens operaties, waarbij de chirurg in real time röntgenbeelden van de patiënt kan raadplegen (zie Figuur 2 voor een illustratie). Deze röntgenbeelden worden gegenereerd in een röntgenbuis (vierkant in Figuur 2) door een proces waarbij stroom op een filament gezet wordt, welke vervolgens de benodigde röntgenstraling afgeeft. Dit filament is dus de kritische component van het iXR systeem: wanneer het filament kapot is, staat het iXR systeem stil. Filamenten worden steeds dunner naarmate er vaker stroom op gezet wordt volgens een fysisch proces, totdat het zo dun is dat het breekt. Een intern onderzoek bij Philips liet zien dat de degradatie van dit filament gemeten kon worden aan de hand van de weerstand: Hoe meer weerstand het filament geeft bij een bepaalde stroomsterkte, des te meer degradatie het filament heeft.



Figuur 2: Een iXR systeem van Philips. De locatie van de röntgenbuis is weergegeven met een vierkant.



Figuur 3: Twee degradatiepaden van twee filamenten van hetzelfde type die gebruikt zijn onder identieke omstandigheden. Op de x-as staat de tijd sinds het filament geïnstalleerd is, en op de y-as staat de degradatie. Een filament faalt wanneer de degradatie 50 bereikt. Het filament in de linker figuur degradeert minder snel dan het filament in de rechter figuur.

Wij hadden de beschikking over een dataset met 52 degradatiepaden (i.e., het historische degradatieverloop van installatie tot falen) van filamenten van hetzelfde type die gebruikt zijn onder identieke omstandigheden. Figuur 3 laat twee voorbeelden van zulke historische degradatiepaden zien. Iedere keer wanneer een röntgenfoto gemaakt wordt kan de degradatie van een filament toenemen met een stochastische hoeveelheid. Aangezien tussen zulke momenten de degradatie gelijk blijft, vertoont het degradatieproces een trappatroon. Op basis van visuele inspectie – en statistische testen bevestigden dit – kunnen we concluderen dat beiden paden gegenereerd zijn door waarschijnlijk hetzelfde stochastische proces (beiden hebben een vergelijkbaar trappatroon), maar met andere parameterwaarden (de lengte van de traptreden en de hoogtes tussen de traptreden zijn overduidelijk verschillend).

Deze dataset laat dus zien dat de aanname dat alle componenten van een bepaald type statistisch hetzelfde zijn ongegrond is. Het gebruiken van deze methode in het geval dat componenten daadwerkelijk statistisch onderscheidbaar zijn – bijvoorbeeld in het geval van deze filamenten – zal dus leiden tot suboptimale onderhoudsmomenten. In de volgende sectie introduceren wij een nieuwe methode die juist veronderstelt dat het degradatieproces van iedere component uniek is en waarvoor op basis van realtime sensor data het optimale onderhoudsmoment

geleerd wordt (zie Figuur 4 voor een schematische illustratie).


Een nieuwe route naar optimale data-gedreven onderhoudsmomenten

In deze sectie beschrijven we een wiskundig model dat in staat is om voor een specifieke component het leren van onbekende parameters van het degradatieproces met behulp realtime sensor data te integreren met de optimalisatie van het onderhoudsmoment.

We modelleren het degradatieproces $\{X_t\}_{t \geq 0}$ van een component als een compound Poisson proces. Dit betekent dat de degradatie op tijdstip t sinds een component geïnstalleerd is geschreven kan worden als:

$$X_t = \sum_{i=1}^{N_t} Y_i, \quad (1)$$

waar N_t een Poisson proces is met parameter λ , en de Y_i 's hebben een geometrische verdeling met parameter p . Het mooie aan een compound Poisson proces is dat de paden ook – net zoals in Figuur 3 – het typische trappatroon vertonen. In de context van Philips is de interpretatie dus dat $\{N_t\}_{t \geq 0}$ de momenten voorstellen waarop we stroom op een fil-



Figuur 4: Nieuwe methode om optimale data-gedreven control limits te *leren*.

lamente zetten, terwijl de Y_i 's de toenames in schade voorstellen als gevolg daar van. We nemen aan dat we het degradatieproces continu kunnen observeren door middel van sensoren, maar dat we alleen onderhoud kunnen plegen op geplande momenten $t \in \{0, 1, 2, \dots\}$. Dit is in lijn met wat er in de praktijk gebeurt. Bijvoorbeeld, onderhoudsmonteurs bezoeken ziekenhuizen op geplande momenten, bijvoorbeeld eens per half jaar, terwijl men wel van afstand het systeem continu kan monitoren. Wanneer de degradatie op zo een gepland moment groter of gelijk is aan een grens, genoteerd met L , dan is de component kapot en moet er correctief onderhoud plaatsvinden wat c_u kost. Als op zo een gepland moment de degradatie kleiner is dan L , dan kan er gekozen worden om de component preventief te vervangen, wat $c_p (< c_u)$ kost, of de component kan in operatie gelaten worden en opnieuw bekeken worden op het volgende geplande moment. De waarde c_u is in het algemeen veel groter dan c_p omdat c_u de kosten van ongeplande stilstand meeneemt, terwijl preventief onderhoud de machine niet ongepland laat stilstaan.

Iedere component is uniek. Dit wil zeggen dat iedere geïnstalleerde component een andere waarde voor λ en p heeft. Deze waarden zijn a-priori onbekend en dienen geleerd te worden van het specifieke degradatiepad dat de component aflegt. We leren deze waarden volgens een Bayesiaanse procedure. Onze kennis van λ en p wordt weerspiegeld door prior verdelingen die we sequentieel updaten met de degradatiedata op basis van Bayes' stelling tot posterior verdelingen, waarbij deze posterior verdelingen een verbeterd beeld geven van onze kennis over λ en p (zie De Heide (2022) voor een excellente uitleg over Bayesiaanse statistiek). We kiezen een conjugate prior verdeling voor zowel λ als p , omdat bij zogenaamde conjugate paren van verdelingen zowel de prior als de posterior verdeling tot dezelfde familie behoren, maar met ge-update parameters. Dit werkt als volgt. Op tijdstip $t = 0$, wanneer een nieuw component geïnstalleerd wordt, dan is λ gamma verdeeld met parameters α_0 en β_0 , en p is beta verdeeld met parameters a_0 en b_0 (dit zijn de prior verdelingen). Stel dat de component nu op tijdstip t sinds de installatie, x degradatie heeft, die veroorzaakt is door n schade momenten (x is

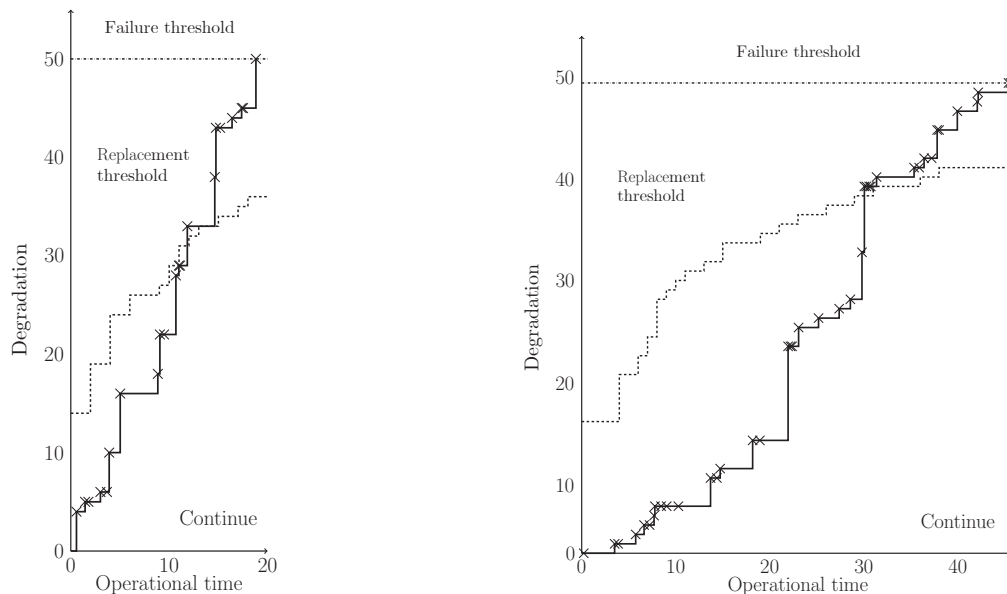
de realisatie van X_t en n is de realisatie van N_t), dan is λ gamma verdeeld met parameters $\alpha_t = \alpha_0 + n$ en $\beta_t = \beta_0 + t$, en p is beta verdeeld met parameters $a_t = a_0 + x$ en $b_t = b_0 + n$ (dit zijn de posterior verdelingen op basis van de verkregen data).

Met deze procedure kunnen we in real time, op basis van x , n , en t , de parameters λ en p leren in toenemende mate van nauwkeurigheid. Bovendien kunnen we op ieder gepland onderhoudsmoment de geüpdatete posterior verdelingen combineren met het compound Poisson proces (zie vergelijking (1)), om voorspellingen te doen over het verloop van het degradatieproces van deze specifieke component. Door deze procedure te integreren in een Markov beslismodel, kun je voor iedere staat (x, n, t) bepalen of het optimaal is om preventief onderhoud te plegen op een gepland onderhoudsmoment. Deze beslissing zal dus afhangen van de sensordata die de individuele component gegenereerd heeft.

Figuur 5 illustreert de optimale onderhoudsmomenten voor twee verschillende filamenten. In deze figuur illustreert de stijgende stippellijn de control limit, zodanig dat preventief onderhoud optimaal is wanneer de degradatie boven deze stippellijn komt. Wanneer we de twee degradatiepaden vergelijken zie je dat het linker filament gemiddeld sneller degradeert ten opzichte van het rechter filament. Je wilt daarom dus ook eerder ingrijpen bij het linker filament op een onderhoudsmoment omdat je een groter risico loopt dat het filament kapot is op het volgende onderhoudsmoment, dan bij het rechter filament. Merk op dat wanneer we volgens de conventionele methode één control limit gekozen hadden voor beide filamenten, je hoogstwaarschijnlijk *te laat* ingegrepen had bij het linker filament en *te vroeg* bij het rechter filament.

De voordelen van geïntegreerd leren en optimaliseren

We sluiten dit artikel af met het kwantificeren van de kostenvoordelen die behaald kunnen worden met ons geïntegreerde model. We hebben een numerieke studie uitgevoerd op basis van de Philips dataset met 52 degradatiepaden waarin we onze methode vergelijken met de conventionele methode. In deze studie selecteerden we telkens x willekeurige degra-



Figuur 5: Twee degradatiepaden (de kruizen markeren de schademomenten) van twee filamenten en de optimale onderhoudsmomenten. Het linker filament wordt vervangen op $t = 12$ met degradatie $x = 29$ en het rechter filament wordt vervangen op $t = 31$ met degradatie $x = 39$.

datiepaden om de prior verdelingen te schatten die noodzakelijk zijn voor de initialisatie van ons model. Daarna berekenden we de onderhoudskosten van ons model zoals die in de praktijk gerealiseerd zouden zijn voor de resterende $52 - x$ degradatiepaden. We herhaalden deze procedure 150 keer om een betrouwbare schatting te krijgen van de gemiddelde onderhoudskosten, met een acceptabel betrouwbaarheidsinterval. Vervolgens vergeleken we deze onderhoudskosten met de onderhoudskosten zoals die onder de conventionele sequentiële methode gerealiseerd zouden zijn. Hierbij bepaalden we eerst puntschattingen voor λ en p op basis van de dezelfde x willekeurige degradatiepaden en berekenden we vervolgens de onderhoudskosten op basis van de resterende $52 - x$ degradatiepaden. In tegenstelling tot ons model, waarbij de control limit wordt bepaald op basis van het degradatieverloop, hanteert de sequentiële methode dezelfde control limit voor alle $52 - x$ degradatiepaden.

Uit de resultaten van onze numerieke studie blijkt overtuigend dat het integreren van leren en optimaliseren aanzienlijke kostenvoordelen oplevert vergeleken met de conventionele sequentiële aanpak. Gemiddeld zouden we met onze methode meer dan 10 procent besparen op de onderhoudskosten van de iXR-systemen van Philips. Deze besparingen zijn te danken aan enerzijds het langer inzetten van de filamenten wanneer we op basis van het realtime degradatie signaal leren dat dit mogelijk is, en ander-

zijds het proactief, eerder vervangen van filamenten die volgens datzelfde realtime degradatiesignaal sneller lijken te degraderen.

Literatuur

- R. De Heide. „Optional stopping met Bayes factors; mogelijkheden en beperkingen”. In: *STATOR* 23.3-4 (2022), p. 22–24.
- C. Drent e.a. „Real-time integrated learning and decision making for cumulative shock degradation”. In: *Manufacturing & Service Operations Management* 25.1 (2023), p. 235–253.

Collin Drent is als universitair docent verbonden aan de groep Technische Bedrijfskunde van de Technische Universiteit in Eindhoven. Hij promoveerde in 2022 cum laude op zijn proefschrift *Structured Learning and Decision Making for Maintenance*. Voor dit proefschrift ontving hij in 2023 de Willem R. van Zwet Award van de VVSOR. Het onderzoek van Collin richt zich voornamelijk op het modelleren en optimaliseren van data-gedreven beslissingsprocessen in de praktijk.
Website: www.collindrent.com
E-mail: c.drent@tue.nl

Melvin Drent werkt als universitair docent in de groep Technische Bedrijfskunde aan de Technische Universiteit in Eindhoven. Hij promoveerde in 2021 op zijn proefschrift *Stochastic Models of Critical Operations* aan de Universiteit van Luxemburg. Momenteel richt Melvin zich voornamelijk op het bestuderen van beslissingsproblemen in diverse domeinen, waaronder voorraadbeheer, onderhoud en gezondheidszorg.
Website: www.melvindrent.com
E-mail: m.drent@tue.nl