

IM FOKUS: MAINTENANCE

Datenbasierte Instandhaltung darf nicht zum Glücksspiel werden

» Moderne Algorithmen, basierend auf neuronalen Netzwerken (Künstlicher Intelligenz), lassen den Traum von Predictive Maintenance immer mehr zur Wirklichkeit werden. Ein grosser Nachteil dieser Ansätze sind die für den Menschen nicht nachvollziehbaren Ergebnisse. Das Netzwerk, verborgen als grosse magische Blackbox, spuckt eine Vorhersage aus, aber die Plausibilität und Zuverlässigkeit kann nicht abgeschätzt werden. In sicherheitskritischen Bereichen kann dies zu katastrophalen Konsequenzen führen. Ob in der chemischen Produktion, im ATEX-Abfüllbereich oder in Mühlen: bei falscher Interpretation der Algorithmen droht ein Berstscheiben-Durchbruch oder gar ein Brand. In diesem Artikel zeigen wir Möglichkeiten für eine automatische Unsicherheitsabschätzung und beschreiben praktische Anwendungen.

Autoren: Luca Biggio, Philipp Schmid und Dr. Iason Kastanis



Flugzeugtriebwerke sind technisch komplexe, aber kritische Systeme. Zustandsprognosen brauchen zwingend eine Quantifizierung der Unsicherheit.

Prognostics and Health Management (PHM) ist ein Fachgebiet, welches sich mit der Entwicklung effizienter Instandhaltungsstrategien befasst. Es geht darum, den Spagat zwischen Kosten und effektiver Lebensdauer von Industrieanlagen zu optimieren. Der weltweite Siegeszug von neuronalen Netzwerken erreicht auch diese Domäne und hat in kurzer Zeit zu einer lebhaften, interdisziplinären Gemeinschaft geführt. Die Rolle des maschinellen Lernens besteht in der automatischen Verarbeitung von

Sensordaten und der Überwachung des Zustands einer Maschine mit dem Ziel, nützliche Informationen zur Charakterisierung ihres Gesundheitszustands zu extrahieren. Dabei stehen zwei Punkte im Fokus:

- Diagnose: hier geht es um die Erkennung und Bewertung einer Anlagenstörung sowie Bestimmung der Ursache und des Schweregrads.
- Prognose: diese hat zum Ziel, eine Zeitprojektion des Gesundheitszustands der Maschine zu schätzen, um möglichst genau vorherzusagen, wann ein Fehler wie stark in der Zukunft auftreten wird.

Die Prognose gleicht einem Blick in die Glaskugel und stellt technisch eine deutlich grössere Herausforderung dar. Nichtsdestotrotz verspricht eine effiziente Gesundheitsprognose eine drastische Senkung der Wartungskosten bei gleichzeitiger Verlängerung der Lebensdauer von Industrieanlagen.

ABSCHÄTZEN DER UNSICHERHEIT EINER PROGNOSE

Bei der Wettervorhersage kennen wir schon lange die Niederschlagswahrscheinlichkeit, nebst der eigentlichen Prognose auch eine Abschätzung der Unsicherheit. Im industriellen Bereich fehlt es aber oft noch genau an dieser. Wartungsmassnahmen haben einen erheblichen Einfluss auf den Durchsatz einer bestimmten Industrieanlage, und eine falsche Entscheidung in diesem Zusammenhang kann zu schwerwiegenden Verzögerungen und übermässig langen Maschinenstillstandszeiten führen. Daher ist es wichtig, vorhergesagte Interventionen an den Maschinen auf zuverlässige Prognosen zu stützen, welche auch mit einer aussagekräftigen Unsicherheitsmarge ausgestattet sind. Nur so kann der Instandhaltungsverantwortliche seine Entscheide auf Analyse aller verfügbaren Informationen planen. Bei risikoreichen Anwendungen kann eine ungenaue Fehlervorhersage zu dramatischen Ergebnissen führen. In diesen Fällen muss jeder Vorhersagealgorithmus aussagekräftige Unsicherheitsabschätzungen liefern, um störende Ereignisse zu verhindern und die Sicherheit zu maximieren.

DEEP LEARNING UND UNSICHERHEITSQUANTIFIZIERUNG

Moderne Algorithmen des maschinellen Lernens – insbesondere Deep Learning – arbeiten oft auf undurchsichtiger Weise, so dass ihre Ergebnisse für den Menschen kaum zu interpretieren sind. Die Blackbox-Natur dieser grossen Netzwerke steht eindeutig im Widerspruch zur Notwendigkeit, vertrauenswürdige Algorithmen für die Instandhaltungsprognose zu entwickeln. Unsicherheitsquantifizierung kann diesen Nachteil abmildern, und ihre Integration in tiefe neuronale Netze ist Gegenstand eines boomenden





Abbildung 1: (Oben) Ladekurve einer Batterie. Die schwarzen Punkte stellen die Messwerte dar, während die blauen Punkte vom Algorithmus vorhergesagt werden. Die blaue Linie stellt die mittlere Vorhersage des Modells dar, während der hellblaue Bereich den Konfidenzintervall (Vertrauensbereich) angibt. (Unten): Die Konfidenz steigt entsprechend der Region, in der keine Daten gemessen werden, und gibt somit Aufschluss über die Unsicherheit der Vorhersagen in diesem Bereich.

den Forschungsfelds in der Deep-Learning-Community. Aktuell werden Techniken des maschinellen Lernens für die Prognose bereits intensiv in der Industrie eingesetzt. Modelle mit Unsicherheitsquantifizierung führen aber unberechtigterweise noch ein Schattendasein. Das CSEM fokussiert sich auf diese Lücke und entwickelt industrielle Konzepte für die «Niederschlagswahrscheinlichkeit der Instandhaltung».

ANWENDUNGSFALL I: BATTERIEN

Die Ladekurve einer Batterie hängt primär von internen chemischen Parametern ab, welche zusätzlich stark von äusseren Einflüssen und Alterungsprozessen beeinflusst wird. In diesem Praxisbeispiel besteht das Ziel darin, die zeitliche Entwicklung des Ladestromes vorherzusagen, wobei nur die ersten 100 Sekunden als Eingangsdaten berücksichtigt werden. Wichtig ist, dass das Modell nicht nur eine

AxiTop montieren, Geräusch und Verbrauch minimieren! Der Ventilator-Diffusor für Wärmetauscher.



Besser:

- 7,2 dB(A)
Geräusch

- 27%
Energieverbrauch

Mit unserem Diffusor sparen Ihre Kunden bis zu 450 CHF pro Jahr pro Ventilator.

- Zusätzlicher Diffusor für optimierten Luftstrom
- Um bis zu 7,2 dB(A) reduzierte Lautstärke
- Bis zu 27% weniger Energieverbrauch
- Einfache Nachrüstung ohne Re-Design

Mehr Informationen für Ihre Anwendung: www.ebmpapst.ch

ebmpapst

Punktschätzung seiner Vorhersagen ausgibt, sondern auch das damit verbundene Vertrauensniveau. Zu diesem Zweck wurde ein in anderen Feldern gut etablierter Ansatz, den so genannten Gaussprozess verwendet. Gaussprozesse eignen sich zur Signalanalyse und bilden ein mächtiges Werkzeug bei der Interpolation, Extrapolation oder Glättung beliebiger Messpunkte. Abbildung 1 zeigt, dass die Prognose des Modells, für welche bloss wenige Eingabedaten zur Verfügung stehen, korrekterweise höhere Unsicherheitswerte zuweist. Dies ermöglicht es dem Benutzer, seine Schlüsse in Abhängigkeit der prognostizierten Unsicherheit zu gewichten.

ANWENDUNGSFALL II: FLUGZEUGTRIEBWERKE

In diesem zweiten Anwendungsfall besteht das Ziel darin, die Restnutzungsdauer (Remaining Useful Life RUL) von Flugzeugtriebwerken unter Berücksichtigung der Unsicherheit der Prognose vorherzusagen. Dazu verwenden wir eine Technik namens Deep Gaussian Process. Diese Methode kombiniert die Vorteile von Deep Learning und Gaussprozessen in einem System. Die Analysen wurden auf einem umfangreichen Datensatz der NASA, welche neun grosse Turbofan-Triebwerke unter realen Flugbedingungen beinhaltet, durchgeführt. Jeder Datensatz umfasst hochaufgelöste Zeitreihen von Sensoren (Eingabe) und ihre entsprechenden RUL-Werte (Ausgabe). Wie in Abbildung 2 (links) zu sehen ist, tendieren die Vorhersagen eines klassischen Netzwerkes dazu, sich gegen Ende der Lebensdauer den wahren Werten anzugleichen. Das Netzwerk ist jedoch übermässig zuversichtlich in Bezug auf seine Schätzungen, selbst wenn diese erheblich vom Ground Truth abweichen. Im Gegensatz dazu (rechts), werden die Vorhersagen des Deep Gaussian Process durch aussagekräftige Unsicherheitsschätzungen unterstützt. Die Werte der Vorhersagevarianz nehmen mit der Zeit ab. Dies

macht physikalisch Sinn, da die Vorhersagen viel unsicherer sind, wenn das System weit vom Ende seiner Lebensdauer entfernt ist. Infolgedessen sind die Vertrauensbereiche, die mit frühen Betriebszeiten verbunden sind, deutlich grösser als die, die dem Ende der Lebensdauer der Maschine entsprechen. Mit anderen Worten, die RUL lässt sich zu Beginn weniger zuverlässig vorhersagen, mit fortschreitender Zeit nimmt die Zuverlässigkeit der Vorhersage zu. Diese Eigenschaft ist von grosser praktischer Bedeutung, da sie die Entwicklung risikobewusster Instandhaltungsstrategien ermöglicht.

ZUSAMMENFASSUNG

Moderne datenbasierte Methoden haben ein grosses Potenzial im Bereich Predictive Maintenance. Ihr Einsatz in industriellen Anwendungen erfordert jedoch, dass sie für die Benutzer besser interpretierbar, nachvollziehbar und transparenter werden. Die gezeigten Methoden der Unsicherheitsquantifizierung sind dazu eine vielversprechende Lösung. Dadurch lassen sich Systeme entwickeln, welche vertrauenswürdiger und zuverlässiger Algorithmen ermöglichen. Für viele risikobehaftete Anwendungen wird dies ein entscheidendes Kriterium darstellen. Die Forschung ist schon weit und arbeitet bereits mit Hochdruck an einfach umsetzbaren Lösungen. Wir gehen davon aus, dass die nächste Generation Algorithmen für die Instandhaltung nebst einer Vorhersage auch die Unsicherheit der Prognose präzise ausgeben kann. <<



Luca Biggio
Doktorand ETH Zürich (Informatik) und CSEM (Robotics and Deep Learning).



Philipp Schmid
Head Research and Business Development Industry 4.0 & Machine Learning, CSEM.



Dr. Iason Kastanis
Senior Expert Machine Learning & Vision, CSEM.

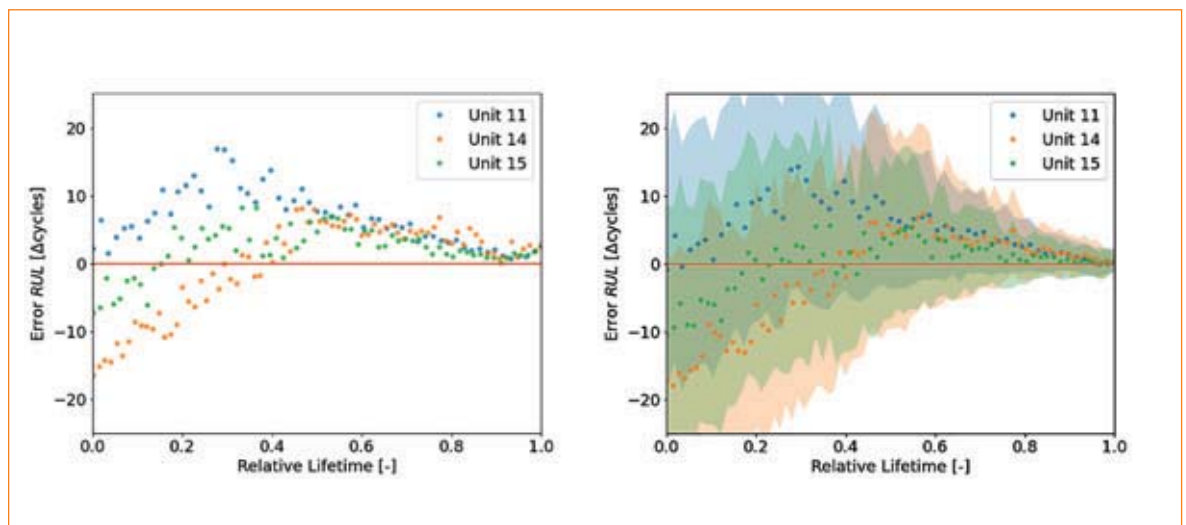


Abbildung 2: (Links) Vorhersagefehler eines klassischen Netzwerkes in Abhängigkeit von der relativen Lebensdauer. (Rechts) Entwicklung der Vorhersageunsicherheit welche vom Deep Gaussian Process ausgegeben wird.