

Merkmalsextraktion mit TSFresh zur lernfähigen prädiktiven Wartung einer Reinstwasser-Aufbereitungsanlage

Tim Trostmann, Martin Patrick Pauli, Martin Golz

Hochschule Schmalkalden, Fakultät Informatik, Blechhammer 4, 98573 Schmalkalden

Abstract

TSFresh ist eine frei verfügbare Python-Funktionsbibliothek, um aus gespeicherten Signalen eine umfassende Anzahl von Merkmalen zu extrahieren. Sie enthält auch skalierbare Hypothesentests, um Merkmale zu selektieren. Dies wurde auf vibroakustische Signale für die prädiktive Instandhaltung angewendet, um eine vorerst binäre Klassifikationsaufgabe zu lösen: die Diskrimination von degenerierten von neuwertigen Filtern. Es zeigte sich, dass TSFresh nicht performant genug war, um den vollständigen Datensatz in angemessener Abarbeitungszeit zu analysieren. Zudem war die Merkmalsselektion nicht so erfolgreich, wie eine selbst erstellte Methodik basierend auf zwei Kriterien, die die Gradient-Boosting-Methode LightGBM zur Verfügung stellt. Mit ihr konnten mittlere Genauigkeiten von 99,4% erzielt werden. Mit der LOSO-CV (leave one subject out cross-validation) wurden Probleme der interindividuellen Variabilität im Datensatz aufgedeckt.

1. Einleitung

Die Instandhaltungskosten nehmen einen großen Anteil an den Gesamtbetriebskosten eines produzierenden Unternehmens ein. Je nach Branche können die Instandhaltungskosten zwischen 15% und 30% der Produktionskosten ausmachen. Von einigen Autoren wurde beispielsweise für die Lebensmittelindustrie der durchschnittliche relative Anteil der Instandhaltungskosten mit etwa 15% angegeben, während sie in der Eisen- und Stahlindustrie, der Zellstoff- und Papierindustrie und anderen rohstoffverarbeitenden Industrien bei bis zu 60% liegen [1,2]. Eine Strategie, diesen Kostenanteil zu senken, besteht in der Abkehr von der regelmäßigen Wartung, teils auch nicht verschlissener Bauteile, hin zur prädiktiven Wartung, bei der kritische Bauteile überwacht werden (condition based monitoring) und die verbleibende sinnvolle Betriebszeit (RUL, Remaining useful life) prädiziert wird. Mit fortschreitender Digitalisierung der industriellen Prozesse (Industrie 4.0) werden immer umfassender Daten gesammelt und Zusammenhänge zwischen verschiedenen Prozessen analysiert, sodass die Wartungsprädiktion durch diese Einbettungsdaten und durch zustandsbezogene Überwachung von systemkritischen Teilen gelöst werden kann.

Datensätze der prädiktiven Wartung sollten möglichst mächtig sein, denn dies ist ein entscheidender Erfolgsfaktor des statistischen Lernens, das immer dann zum Einsatz kommt, wenn eine Modellbildung des zu untersuchenden Prozesses zu schwierig ist. Da die Beobachtungen, meist Sensorsignale, vielen Einflüssen unterliegen, sind die Nutzsignale von den überlagerten Zufallsanteilen schwer zu separieren, so dass optimale Merkmale extrahiert und selektiert werden sollten. Dadurch erreicht man eine beträchtliche Reduktion der Dimensionalität der Eingangsvariablen für das statistische Lernen. Diese Lernverfahren wiederum müssen optimiert werden, sodass es weder zu

Über- noch zu Untereinpassungen des intrinsischen Modells an die gegebene Verteilung des Eingangsvariablen kommt.

In diesem Beitrag soll demonstriert werden, wie aus einem Datensatz der prädiktiven Wartung mit einer aktuell verfügbaren Funktionsbibliothek automatisch eine umfangreiche Menge diverser Merkmale extrahiert werden kann und wie diese angewendet werden können, um eine generalisierungsfähige Abbildung der Merkmalsvektoren auf die Zielvariablen zu erzielen. Der Einfachheit halber soll die Zielvariable binär sein, d.h. inaktiver oder degenerierter Zustand eines kritischen Bauteils.

2. Material und Methoden

Bei den Daten, welche zum Trainieren und Validieren der statistischen Lernmethode verwendet wurden, handelt es sich um Signalaufzeichnungen, welche direkt für das Ziel der prädiktiven Instandhaltung (predictive maintenance) aufgenommen wurden. Erfasst wurden diese an einer Anlage zur Filterung von Reinwasser auf Reinstwasserniveau. Wie in jedem Filtersystem degeneriert der Filter zunehmend, bis er schließlich so hohen Strömungswiderstand aufweist, dass Pumpen wegen thermischer Überlastung abschalten müssen. Es wurden Strömungsgeräusche indirekt als Körperschall an Außenflächen diverser Bauteile der Filteranlage (Rohre, Vorfilter, Umkehrosmose-Aggregat) mithilfe von Universal-Beschleunigungssensoren (KS78B100, Firma: Metra Mess- & Frequenztechnik e.K., Radebeul, Deutschland) gemessen. Für beide Klassen wurde ein Zeitraum von 48 Stunden Pumpenlaufzeit jeweils vor und nach einem Filterwechsel gewählt. Insgesamt lagen Aufzeichnungen von fünf Filterwechseln vor. Die Sensoren erfassen Schwingungen im vibroakustischen Bereich, der unterhalb von 1Hz beginnt und über 100 kHz endet. Hier wurde aus Aufwandsgründen mit einer Abtastfrequenz von 16 kHz und passenden Anti-Aliasing-Tiefpass-Filtern aufgezeichnet und somit die obere Grenzfrequenz auf 8 kHz beschränkt. Bei 240 Stunden Aufnahmezeit entspricht dies ca. 13,8 Milliarden Abtastwerten. Diese Signale werden später in 60 Sekunden lange Signalsegmente unterteilt, um möglichst viele Beispiele für das statistische Lernen zu erhalten. Die damit verbundene Einschränkung der unteren Grenzfrequenz wird als unkritisch erachtet, weil Schwingungen mit Periodendauern von mehr als 60s als irrelevant angenommen werden.

Die Merkmalsextraktion wurde mit der offen zugänglichen Python-Bibliothek TSFresh automatisiert durchgeführt [3]. Diese Bibliothek ist in Version 0.19.0 in der Lage, 77 verschiedene Merkmalstypen zu extrahieren. Da viele Merkmalstypen mehrdimensional sind, können durchaus Dimensionalitäten der entstehenden Merkmalsvektoren von über 1.000 entstehen. Beispielsweise sind folgende Merkmalstypen enthalten: Momente und Perzentile der Amplitudenverteilung, Signalenergie, Entropie, approximative Entropie, diskrete Fourier-Transformation, spektrale Leistungsdichten, Cepstrum-Koeffizienten, Hilbert-Transformation, Zustandsraum-Variablen und diskrete Wavelet-Transformation.

Im Anschluss wurden die erzeugten Merkmale mit manueller und automatischer Relevanzbestimmung selektiert. Die automatische Relevanzbestimmung erfolgt simultan zum Trainingsprozess, der mit der Gradient-Boosting-Methode LightGBM [4] durchgeführt wurde. Im Ergebnis des Trainings entsteht eine kontinuierliche Abbildung, die beliebige Merkmalsvektoren auf eine binäre Klassennummer zuordnet.

Es wurden zwei Kreuzvalidierungsverfahren verwendet. Zum einen die RRSS-CV (repeated random subsampling) sowie die LOSO-CV (leave-one-subject-out). Die RRSS-CV untergliedert sich im Wesentlichen in folgende sechs Schritte (Abbildung 1):

- 1.) Der Datenindex wird zufällig permutiert, um zu gewährleisten, dass die Trainingsbeispiele während des Trainings in zufälliger Reihenfolge verarbeitet werden.
- 2.) Der Datensatz wird in einem definierten Verhältnis in Trainings- und Validierungsmenge aufgeteilt, z. B. 80:20, 90:10, 95:5. Hier wurde 80:20 gewählt.
- 3.) Das Training der Klassifikationsmethode LightGBM wird ausschließlich am Trainingsatz durchgeführt.
- 4.) Statistische Schätzung der Genauigkeiten an Trainings- und Validierungsmenge
- 5.) M -malige Wiederholung von Schritt 1 an. M kann frei gewählt werden. Hier wurde mit $M = 5$ ein relativ kleiner Wert gewählt aufgrund der begrenzt verfügbaren Rechenzeiten.
- 6.) Finale Schätzung von Mittelwert und Standardabweichung der Trainings- und Validierungsgenauigkeit über den M Wiederholungen des Schrittes 4.).

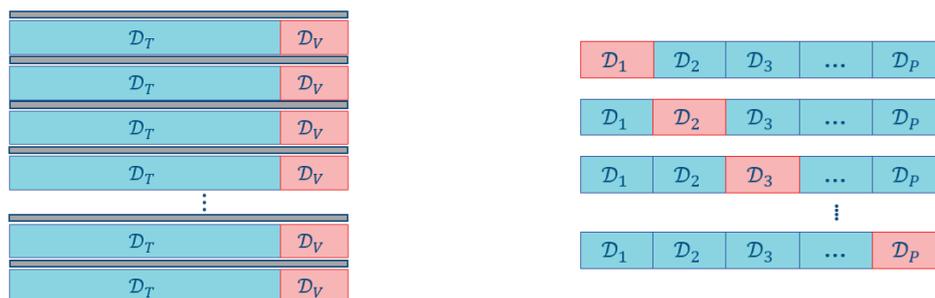


Abbildung 1: Links: Kreuzvalidierung durch wiederholte zufällige Partitionierung (RRSS-CV; repeated random subsampling cross-validation). Rechts: Leave-One-Subject-Out-Kreuzvalidierung (LOSO-CV). Bei RRSS-CV wird nach zufälliger Permutation des Datenindexes (horizontale graue Balken) der Datensatz \mathcal{D} in eine Trainingsmenge \mathcal{D}_T und eine Testmenge \mathcal{D}_V aufgeteilt. Bei LOSO-CV wird \mathcal{D} anhand einer kategorialen Variable $p = 1, 2, \dots, P$ in Trainingsmenge (blau) und Validierungsmenge (rot) aufgeteilt.

Bei der LOSO-CV sind folgende Schritte auszuführen (Abbildung 1):

- 1.) Eine Gruppe bildet die Validierungsmenge, alle anderen Gruppen bilden die Trainingsmenge.
- 2.) Das Training der Klassifikationsmethode LightGBM wird ausschließlich am Trainingsatz durchgeführt.
- 3.) Statistische Schätzung der Genauigkeiten an Trainings- und Validierungsmenge
- 4.) P -malige Wiederholung von Schritt 1 an. P ist die Anzahl der Gruppen.
- 5.) Finale Schätzung von Mittelwert und Standardabweichung der Trainings- und Validierungsgenauigkeit über den P Wiederholungen des Schrittes 3.).

Bei RRSS-CV werden Kategorien, hier sind es die individuellen Filter, innerhalb des Datensatzes nicht berücksichtigt. Dadurch kann an Beispielen aller Filter trainiert werden und anschließend wird auch an Beispielen aller Filter validiert. Die Validierungsgenauigkeiten sind allerdings optimistisch verzerrt. Bei der LOSO-CV wird kategorienbezogen eine Teilmenge aus dem Training herausgehalten und nur zum Validieren genutzt wird. Die sich statistisch zu schätzende Validierungsgenauigkeit ist dadurch nicht mehr durch den Einfluss der Kategorien verzerrt. Man erreicht so besser eine Abbildung finden, die unabhängig von der kategorialen Variable ist, und umgeht das sogenannte Data-Leakage-Problem [5].

Die Qualität der Merkmalsselektion durch TSFresh wurde abschließend mit einer selbst entwickelten Methode verglichen. Sie basiert auf den Validierungsergebnissen mit der Klassifikationsmethode LightGBM. Zuerst wurde eine Merkmalsextraktion mit TSFresh durchgeführt, die zu 789 Merkmalen führte. Im LightGBM-Trainingsprozess wurde ein Vektor berechnet, der für jedes Merkmal den Gewinn (gain) und den Teilungszähler (split count) beinhaltet. Der Gewinnwert ist gleich der Veränderung der Verlustfunktion bei Hinzunahme des Merkmals zu den Trainings-Eingangsdaten. Der Teilungszähler zeigt hingegen, wie oft ein Merkmal bei der Generierung des Entscheidungsbaumes eingesetzt wurde. Beide Werte sind Maße für die Relevanz eines Merkmals. Mit Schwellwerten können Merkmale selektiert werden, die entweder häufig genug zu Entscheidungen (splits) oder zur Genauigkeitssteigerung (gain) beigetragen haben. Die maximum-normierten Schwellwerte können bspw. auf 10% fixiert werden.

3. Ergebnisse

Während mit RRSS-CV (repeated random sub-sampling cross-validation) eine mittlere Klassifikationsgenauigkeit von $99,4 \pm 0,6$ % erzielt wurde, schwankte die Klassifikationsgenauigkeit stark bei LOSO-CV (leave one subject out cross-validation). Die LOSO-CV ist die praxishere Methode, denn sie simuliert den Fall, dass zukünftig neu hinzukommende Datensätze durch eine Methode klassifiziert werden müssen, die nicht mehr trainiert wird, sondern deren Abbildung (Modell) fixiert ist. Dies entspricht dem Abruf-Betrieb nach beendetem Trainings- und Optimierungsprozess.

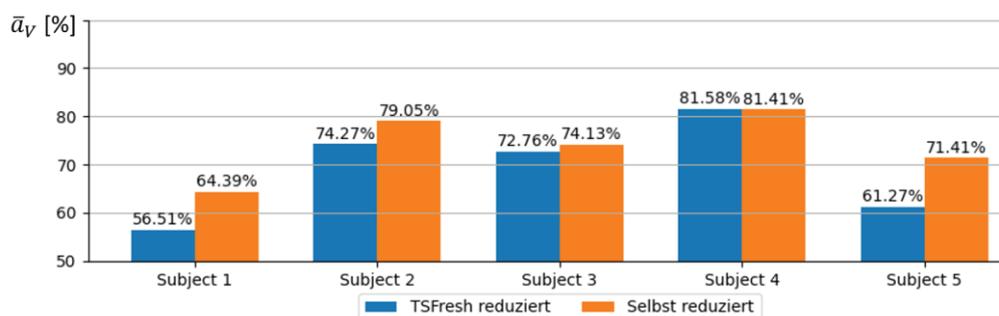


Abbildung 2: Mittelwerte der Klassifikationsgenauigkeit an Validierungsmengen (Ordinate) für fünf individuelle Filterwechsel (Abszisse). Die als Eingangsvariablen verwendeten Merkmale wurden einerseits durch TSFresh (blau) und andererseits durch eine eigene Methodik selektiert (orange).

Es zeigte sich im Weiteren, dass weder die vollständigen noch die reduzierten Merkmalsvektoren die Diskrepanz der LOSO-CV-Ergebnisse bzgl. der RRSS-CV-Ergebnisse verringern können. Mit den Merkmalsvektoren, die selbst reduziert wurden, konnte die Klassifikationsaufgabe am genauesten erfüllt werden (Abbildung 2). Der finale Vergleich

zeigt für jeden einzelnen Filterwechsel, dass die mithilfe von TSFresh selektierten Merkmale (blau) zu geringeren mittleren Klassifikationsgenauigkeiten führen im Vergleich zur selbst entwickelten Methodik (orange); die Unterschiede betragen bis zu 10,2%. Allerdings waren die Verbesserungen nicht einheitlich und liegen dennoch unterhalb der RRSS-CV, die bei Klassifikationsgenauigkeiten von durchschnittlich 99,4% endete.

4. Diskussion

Die durch TSFresh mögliche Reduzierung der Merkmale anhand Hypothesentests hatte bei dem hier gegebenen Datensatz nur einen mäßigen Erfolg; ein Filterwechsel konnte nur mit 56,5% Genauigkeit validiert werden, sodass das entwickelte und trainierte Modell nur 6,5% über der Zufallsentscheidung liegt. Die eigene Merkmalsselektionsmethode erzielte Genauigkeiten zwischen 64,4% und 84,4%. Diese Ergebnisse liegen weit unterhalb der mit RRSS-CV erzielten mittleren Genauigkeit von 99,4%. Letzteres zeigt, dass die Merkmale prinzipiell gut geeignet sind für die Diskrimination der beiden Klassen des intakten und des degenerierten Filters.

Die Verschlechterungen bei LOSO-CV könnten folgende Gründe haben.

1. Qualität der Daten

Es ist nichts Näheres über die Zeitintervalle der Filterwechsel bekannt. Die Filter wurden innerhalb regelmäßiger Wartungsroutinen ausgetauscht, wobei es keine fixierten Kriterien und keine exakten Intervalle gab. Deshalb ist nicht auszuschließen, dass manchmal Filter ausgetauscht wurden, obwohl sie noch nicht stark degeneriert waren. Dies würde allerdings die Klassifikationsaufgabe erheblich beeinträchtigen, weil die Zuverlässigkeit der Zielvariable (hier: Klassennummer 0/1) eine wichtige Voraussetzung ist. Ebenfalls sind zusätzliche Schallquellen an der Anlage nicht auszuschließen, die in manchen Zeiträumen aktiv waren und in anderen nicht. Diese würden ebenfalls die LOSO-CV aber nicht die RRSS-CV beeinträchtigen. Das Gleiche gilt für Änderungen an der Anlage und für langzeitliche Schwankungen der Wasserqualität. Jegliche Änderung des Gesamtprozesses zwischen den Filterwechseln könnte für die reduzierte mittlere Genauigkeit der LOSO-CV verantwortlich sein.

2. Reduzierung des Datenumfangs

Die mit 16 kHz aufgenommenen vibroakustischen Messungen erwiesen sich für einen einzigen Rechner als zu umfangreich, um diese mit TSFresh in akzeptabler Rechenzeit zu berechnen. Selbst das Einteilen in unterschiedliche Segmentlängen verbesserte die Berechnungszeit ab einer gewissen Größe nicht mehr wesentlich. Deshalb musste die Datenrate von 16 kHz auf mindestens 160 Hz reduziert werden, damit eine vollständige Merkmalsextraktion durchgeführt werden konnte. Damit ist eine drastische Reduktion der oberen Grenzfrequenz verbunden und für einige Merkmalsextraktionsmethoden (bspw. Entropie-Schätzungen) eine Verringerung des Stichprobenumfangs um Faktor 100. Diese Limitierung zeigt, dass TSFresh noch nicht ausreichend performant für größere Signalanalyse-Projekte ist.

3. Spezialisierung an Untermengen

Trotz der TSFresh-internen Hypothesentests zur Bewertung der Merkmalsrelevanz verblieben in der Analyse viele Merkmale, die zu geringe Relevanz bezüglich der Genauigkeit an Validierungsmengen haben. So könnte sich die Gradient-Boosting-Methode auf

Besonderheiten in der Verteilung irrelevanter Merkmale zu sehr spezialisiert haben, die für einzelne Filter von Vorteil sind, aber nicht für alle. Die LOSO-CV dient der Aufdeckung solcher individuellen Überanpassungen.

Für zukünftige Arbeiten ist ein wesentlich erhöhter Umfang an Filterwechseln erforderlich, um die interindividuellen Streuungen der Merkmalsvektoren eingehender studieren zu können.

Quellen

- [1] Mobley RK (2002) An introduction to predictive maintenance. Elsevier
- [2] Ringfeder Power Transmission GmbH (2016) Zahlen und Fakten zu Wartung und Instandhaltung. Online available: <https://blog.ringfeder.com/de/wartung-instandhaltung-zahlen-und-fakten>
- [3] Christ M, Braun N, Neuffer J, Kempa-Liehr AW (2018) Time series feature extraction on basis of scalable hypothesis tests. *Neurocomputing* 307:72-77
- [4] Ke G, Meng Q, Finley T, Wang T, et al. (2017) LightGBM: A highly efficient gradient boosting decision tree. *Adv Neural Inf Proc Syst* 30:3146-54
- [5] Kaufman S, Rosset S, Perlich C, Stitelman O (2012) Leakage in data mining: Formulation, detection, and avoidance. *ACM Trans Knowl Discov Data (TKDD)* 6(4):1-21