

Merkmalsbasierte luftakustische Diagnose von Druckluftleckage mithilfe maschineller Lernverfahren

Daniel Diaz Ocampo¹, Mariya Lyashenko², Stefan von Dosky² Michael Heizmann¹

¹Institut für Industrielle Informationstechnik, KIT, Hertzstraße 16, Geb. 06.35, 76187 Karlsruhe Deutschland

²Siemens AG, Digital Industries, DI PA TI DPO, Östliche Rheinbrückenstr. 50, 76187 Karlsruhe Deutschland

Zusammenfassung

Druckluftsysteme sind ein wichtiger Bestandteil der technischen Infrastruktur in einer industriellen Anlage. Druckluft ist ein sehr teurer Energieträger in der Industrie. In jedem Druckluffterzeugungs- und -verteilssystem treten Leckagen auf, die den Energieverbrauch und somit die entstehenden Kosten unnötig erhöhen können. Die frühzeitige Erkennung von Leckagen und die Minimierung von Leckagemengen ist daher essenziell für den wirtschaftlichen Betrieb von Anlagen.

Im Beitrag wird eine universelle Methode zur Erkennung von Druckluftleckagen vorgestellt. Auf Grundlage von Merkmalen, die aus luftakustischen Signalen gewonnen werden, findet die Klassifikation von Leckagen statt. Dabei kommen u.a. statistische Merkmale und Merkmale zur Beschreibung der spektralen Energieverteilung zum Einsatz. Für die Auswahl, der am besten geeigneten Merkmale wird eine Varianzanalyse verwendet. Für die Klassifikation erweist sich ein Random-Forest als geeignet. Ergebnisse an Testdaten aus einer experimentellen Anlage zeigen die prinzipielle Eignung der Vorgehensweise.

Keywords: Druckluftleckage, Mikrofonsensor, Machine Learning, Frequenzanalyse

Einleitung

Die effiziente Nutzung von Ressourcen und die Gewährleistung der Wirtschaftlichkeit sind in der heutigen Geschäftswelt von entscheidender Bedeutung. Insbesondere beim Umgang mit Druckluftsystemen ist es unerlässlich, Lecks zu identifizieren und zu reparieren, um sowohl finanzielle Verluste zu minimieren als auch einen verantwortungsvollen Umgang mit Ressourcen sicherzustellen. Dieser Aspekt wird in Abbildung 1 anschaulich verdeutlicht. Darüber hinaus spielt die Sicherheit der Mitarbeiter eine maßgebliche Rolle, da Druckluftlecks auch potenzielle Gefahrenquellen für den Menschen darstellen können.

Um diesen Herausforderungen zu begegnen, wird in diesem Paper ein Ansatz vorgestellt, der maschinelles Lernen auf der Grundlage von akustischen Daten nutzt, um eine Aussage darüber zu treffen, ob es eine Leckage in einem Druckluftsystem gibt oder nicht. Durch die Analyse von akustischen Signalen, die von Anlagenteilen mit potenziellen Leckstellen erfasst werden, kann das vorgestellte System frühzeitig auf mögliche Lecks hinweisen und Unternehmen die Möglichkeit geben, proaktiv Maßnahmen zu ergreifen. Dieser Ansatz bietet

nicht nur eine effiziente Methode zur Überwachung von Druckluftsystemen, sondern ermöglicht es auch, wirtschaftliche Schäden zu minimieren und die Sicherheit am Arbeitsplatz zu gewährleisten.

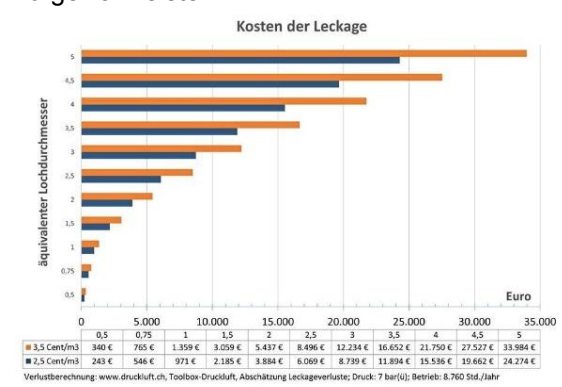


Abbildung 1: Mögliche wirtschaftliche Verluste, die bei einer Leckage entstehen können, entnommen aus [1].

In diesem Beitrag werden zunächst die Datenerfassung unter verschiedenen Anlagenbedingungen und die dadurch erzeugten Testdaten vorgestellt. Die angewandte Methode zur Leckageerkennung, einschließlich der Merkmalsauswahl und der Datenverarbeitung, wird beschrieben. Zudem werden verschiedene Klassifikationsmethoden und eine Spektral-

analyse verwendet, um die Leckstellen zu detektieren und zu analysieren. Die Ergebnisse der Studie werden präsentiert, diskutiert und mögliche Herausforderungen sowie alternative Ansätze werden erörtert. Das Paper trägt dazu bei, das Verständnis für die Überwachung von Druckluftsystemen zu erweitern und effektive Strategien zur Leckageerkennung und -behebung zu entwickeln.

Sensor und Setup

Zur Erfassung der luftakustischen Messsignale kommen batteriegespeiste Mikrofonsensoren zum Einsatz, die in verfahrenstechnischen Anlagen räumlich verteilt angeordnet werden können. Es werden wiederholt kurze Schallsignale erfasst (16384 samples, 144,1 kS/s sample rate), welche als Vektoren der Länge 16384 interpretiert werden können. Sie werden drahtlos an eine Cloud übertragen und dort ausgewertet.

Es wird vermutet, dass es eine umgekehrt proportionale Abhängigkeit der Mittenfrequenz des Leckagegeräusches vom Durchmesser des Loches, aus dem die Druckluft entweicht, existiert. Dies lässt sich aus der akustischen Theorie von Düsen vermuten. Gleichzeitig ist die Dämpfung des Leckagegeräusches in Luft proportional zur Frequenz.

Datensatz

Die vorliegende Aufgabenstellung ist es, in einem industriellen Umfeld mithilfe von luftakustischen Signalen Leckagen in pneumatischen Systemen zu erkennen. In einer solchen Umgebung treten viele verschiedene Störgeräusche auf. Des Weiteren kommt es oftmals zu einem regulären Austritt von Luft, beispielsweise zur Bewegung von Stellventilen, welche einer Leckage sehr ähnlich ist. Der Ansatz dieser Arbeit ist, mithilfe von maschinellem Lernen die Leckage von anderen Störungen zu unterscheiden. Zu diesem Zweck wurde ein Datensatz erstellt, der neben Beispielen zu Leckage auch andere Störungen wie Anlagengeräusche oder Ventilstellvorgänge enthält. Es wurden verschiedene Durchmesser der Leckage getestet (0,18; 0,3; 0,45; 0,5 mm). Im Trainingsdatensatz sind Messungen mit bzw. ohne Leckage enthalten. Aus diesen Messungen wurden 70% dem Trainings- und 30% dem Testdatensatz zugeordnet. Die Aufteilung erfolgte zufällig, um sicherzustellen, dass ausreichend Leckagen in beiden Datensätzen vorhanden sind. Zudem wurden weitere Daten unter denselben und unter anderen Rahmenbedingungen

aufgenommen, um die Generalisierbarkeit der erstellten Modelle zu überprüfen. Diese weiteren Datensätze wurden nur zum Testen des Modells verwendet. Dabei wurde unter anderem eine Industrieanlage eingesetzt, um übliche Störgeräusche zu simulieren. Diese Störgeräusche enthalten unter anderem Ventilgeräusche, bei denen es zum Luftaustritt kommt. Diese sind einer Leckage besonders ähnlich und stellen eine große Herausforderung für die Klassifikation dar. Des Weiteren wurde der Abstand zur Leckagestelle (1; 6; 10 m) variiert.

Methode

Es bietet sich an, die Erkennung der Leckage mithilfe maschineller Lernmethoden zu realisieren. Dabei ist ein etablierter Ansatz, die Klassifikation nicht anhand der Rohsignale, sondern anhand aus den Signalen extrahierter Merkmale durchzuführen. Dazu werden Merkmale aus kurzen Teilsignalen mit definierter Länge berechnet und anschließend die damit erzielte Performanz bei der Klassifikation bewertet. Diese Bewertung wird als Grundlage verwendet, um die besten Merkmale auszuwählen und mit diesen verschiedene Klassifikatoren in dem so erstellten Merkmalsraum zu trainieren. Es wurden verschiedene etablierte Methoden getestet, wobei der Random-Forest die besten Ergebnisse liefert. Im Folgenden wird zuerst ein Überblick über die verwendeten Merkmale gegeben, dann die Auswahl der besten Merkmale beschrieben und zu guter Letzt die Klassifikation mittels Random-Forest erklärt.

Merkmale

Für diese Arbeit wurden über 100 unterschiedlichste Merkmale beispielsweise aus der Statistik oder dem Frequenzbereich berechnet und anschließend mithilfe einer Varianzanalyse auf ihre Tauglichkeit zur Klassifikation untersucht. Im Folgenden werden lediglich die besten, welche auch später zur Anwendung kommen, vorgestellt.

Vorverarbeitung

Untersuchungen haben ergeben, dass die Klassifikationsgüte steigt, wenn nicht das gesamte Signal verarbeitet wird, sondern wenn es vorher in Teilsignale konstanter Länge unterteilt wird. Diese Teilsignale werden im Folgenden Segmente genannt und überlappen sich nicht. Da viele Merkmale auf der Fourier-Transformation beruhen, ergeben für eine effiziente Realisierung Zweierpotenzen als Segmentlänge am meisten Sinn. Unter-

suchungen haben gezeigt, dass eine Segment-Größe von $N_x = 8192$ Samples, was einer Zeitspanne von ca. 57 ms entspricht, optimale Ergebnisse mit den nachfolgenden Algorithmen liefert. Die Aufgabe besteht nun darin, den Maschinenzustand für jedes einzelne Segment zu klassifizieren. Zu diesem Zweck werden aus jedem Segment Merkmale berechnet, welche die Grundlage für die anschließende Klassifikation bilden.

Fourier-Koeffizienten

Um grundlegende Eigenschaften des Spektrogramms dem Klassifikator zu vermitteln, wird die Fast-Fourier-Transformation

$$X_k = \sum_{n=0}^{N-1} x_n e^{-j2\pi k \frac{n}{N}}, \quad k = 0, \dots, N_x - 1 \quad (1)$$

gemäß [2] aus den Segmenten berechnet. Die zugehörigen Frequenzen sind durch

$$f_k = \frac{k - \frac{N_x}{2}}{N_x} f_A$$

definiert. Da es sich hier um reelle Signale handelt, weisen diese ein symmetrisches Spektrum auf, weswegen für die weiteren Merkmale die nicht negativen Frequenzen ($k = 0, \dots, N_f - 1$ mit $N_f = \frac{N_x}{2}$) verwendet werden.

Um weniger, aber robustere Merkmale im Hinblick auf Signalrauschen zu erhalten, wird das Ergebnis in $N_B = 20$ gleich große Frequenzbänder unterteilt und die entsprechenden relativen Absolutwerte

$$\bar{X}_i = \sum_{k=iB}^{(i+1)B-1} \frac{|X_k|}{\sum_{n=0}^{N_f-1} |X_n|}, \quad i = 0, \dots, N_B - 1,$$

mit $B = \frac{N_f}{20}$, werden für jedes Band summiert. Diese Werte werden normiert, so dass ihre Summe eins ergibt, wodurch das Ergebnis den prozentualen Beitrag jedes Frequenzbandes zur Gesamtsumme repräsentiert. Diese Herangehensweise ermöglicht eine recheneffiziente Darstellung des Spektrogramms und gleicht geringfügige Frequenzvariationen in Frequenzbändern aus.

Rolloff-Frequenz

Um die Lage der Signalenergie über einem Spektrum zu beschreiben, können die sogenannten „Rolloff-Frequenzen“ berechnet werden, wie sie in [3] beschrieben werden. Diese beschreiben, unterhalb welcher Frequenz ein bestimmter Teil der Signalenergie liegt. Es wird dazu das Spektrum mittels Gleichung (1) berechnet und daraus die Energieanteile des Spektrums aufsummiert

$$E_{x,J} = \sum_{k=0}^{N_J-1} |X_k|^2 / \|X\|^2.$$

Anschließend wird durch das Quadrat der Gesamtenergie $\|X\|^2$ geteilt, um die prozentuale Verteilung der spektralen Energie zu erhalten. Als $x\%$ -Rolloff-Frequenz wird die zu N_J gehörige Frequenz f_J bezeichnet, unterhalb welcher $x\%$ der prozentualen Signalenergie $E_{x,J}$ liegt.

Spektraler Kontrast

Der spektrale Kontrast [4] bildet den Vergleich zwischen den Frequenzbereichen mit der meisten Signalenergie und den Frequenzbereichen mit der niedrigsten Signalenergie. Dazu werden die Ergebnisse der Fourier-Transformation wie in Gleichung (1) berechnet und anschließend in $Q = 6$ Bänder mit jeweils $N_Q = \frac{N_f}{Q}$ spektralen Werten eingeteilt. Dann werden die Werte der Größe nach sortiert

$$|\tilde{X}_{q,0}| \leq |\tilde{X}_{q,1}| \leq \dots \leq |\tilde{X}_{q,N_Q-1}|$$

und anschließend die niedrigsten mit den höchsten Werten verglichen. Um Rauscheinflüsse zu unterdrücken und ein robusteres Merkmal zu erhalten, wird der Mittelwert über die α niedrigsten Werte

$$V_{q,\alpha} = \frac{1}{\alpha} \sum_{k=0}^{\alpha-1} |\tilde{X}_{q,k}|,$$

bzw. höchsten Werte

$$P_{q,\alpha} = \frac{1}{\alpha} \sum_{k=N_f-\alpha}^{N_f-1} |\tilde{X}_{q,k}|$$

gebildet. Im Anschluss wird, laut Definition, der Logarithmus des Verhältnisses gebildet:

$$S_q = \log\left(\frac{P_{q,\alpha}}{V_{q,\alpha}}\right) = \log\left(\frac{\sum_{k=\alpha}^{N_f-1} |\tilde{X}_{q,k}|}{\sum_{k=0}^{\alpha-1} |\tilde{X}_{q,k}|}\right).$$

Da der Logarithmus eine streng monotone Funktion ist, kann sie, um Rechenaufwand zu sparen, für eine Klassifikation mittels Schwellwertbildung, wie sie in dieser Arbeit eingesetzt wird, vernachlässigt werden. Dieses Merkmal enthält Informationen darüber, wie sehr die stark auftretenden Frequenzen das Gesamtsignal dominieren. Dies ist insbesondere bei der Unterscheidung verschiedener Rauschprozesse von Vorteil.

Spektrale Bandbreite

Als ein weiteres Merkmal kann die spektrale Bandbreite, wie sie in [5] beschrieben wird, verwendet werden. Sie ist durch

$$W = \sqrt{\frac{\sum_{k=0}^{N_f-1} |X_k| (f_k - f_{SP})^2}{\sum_{k=0}^{N_f-1} |X_k|}}$$

definiert, wobei

$$f_{SP} = \sum_{k=0}^{N_f-1} f_k \frac{|X_k|}{\sum_{k=0}^{N_f-1} |X_k|}$$

der spektrale Schwerpunkt ist. Dieser kann auch als eigenständiges Merkmal berechnet werden, wobei er allerdings für diese Arbeit keine Relevanz hat. Rauschprozesse wie eine Leckage besitzen oftmals ein breitbandiges Spektrum, daher eignet sich die spektrale Bandbreite gut dazu, die Leckage von anderen schmalbandigen Ereignissen zu unterscheiden.

MFCCs

Mel-Frequency Cepstral Coefficients (MFCCs), wie sie in [6] beschrieben werden, werden verwendet, um ein Spektrum in wenige Schlüsselparameter zu kondensieren. Um dies zu erreichen, wird ein Spektrum wie nachfolgend beschrieben auf der Mel-Skala berechnet und dann mithilfe einer Kosinustransformation in eine Reihe von Koeffizienten umgewandelt.

Im ersten Schritt wird eine diskrete Fourier-Transformation berechnet, wobei jedoch zuvor die Teilsignale mit einem Hanning-Fenster multipliziert werden. Das Ergebnis dieser Transformation kann auch als Kurzzeit-Fourier-Transformation des gesamten Signals interpretiert werden und liefert die Amplituden X_k mit den entsprechenden Frequenzen f_k . Um nun die Anzahl der Merkmale zu reduzieren, wird die Energie des Spektrums mithilfe von J Dreiecksfiltern $\varphi_{j,k}$ zu einzelnen Kanälen

$$E_j = \sum_{k=0}^{N_f-1} \varphi_{j,k} |X_k|, \quad j = 0, \dots, J-1$$

zusammengefasst. Die Filter überlappen sich und besitzen bei höheren Frequenzen eine höhere Bandbreite. Die Aufteilung in diese Kanäle kann als Zuordnung der Frequenzen auf eine Mel-Skala interpretiert werden. Die Anzahl der berechneten Merkmale pro Abschnitt hängt von der Anzahl der für diesen Schritt gewählten Kanäle ab.

Im letzten Schritt wird eine diskrete Kosinustransformation

$$c_l = \sum_{j=0}^{J-1} \cos\left(l \frac{\pi}{J} (j + 0,5)\right) \log_{10} E_j,$$

$$l = 0, \dots, L-1$$

über den Logarithmus der Energien durchgeführt mit $L = 20$.

Ableitungen

Da eine Leckage, sowie verschiedene andere Störeffekte, charakteristische breitbandige Rauscheinflüsse sind, zeigen sich in den Signalen meist sehr steile Flanken bzw. Sprünge. Daher kann es für einige Merkmale sinnvoll sein, sie nicht nur aus dem eigentlichen Signal, sondern aus der ersten bzw. zweiten Ableitung zu berechnen. Diese lässt sich durch

$$x_n^{(1)} = \frac{x_{n+1} - x_{n-1}}{2h}$$

berechnen, wobei der Abstand zwischen zwei Samples h nicht der inversen Abtastrate entspricht, sondern auf 1 gesetzt wird. Dies vereinfacht die Berechnung und hat keine Auswirkung auf die Methodik, da es sich lediglich um einen Vorfaktor handelt, welcher in den Merkmalen ebenfalls nur ein Vorfaktor ergibt. Da die Entscheidungsgrenzen im Klassifikationsschritt anhand von Testdaten gelernt werden, hat das keinen Einfluss auf die Klassifikationsleistung.

Die zweite Ableitung lässt sich entsprechend durch zweifaches Anwenden der Gleichung berechnen.

Merkmalsauswahl

Aus einem Teilsignal wurden für diese Arbeit 104 verschiedene Merkmale berechnet. Es ist nicht sinnvoll, alle von ihnen zu verwenden, da manche Merkmale beispielsweise stark mit Rauschen überlagert sein können, wodurch ihr Einsatz in einem Klassifikator zu fehlerhaften Ergebnissen führen kann. Es wird auch einzelne Merkmale geben, die überhaupt nicht zur Klassifikation der Leckage geeignet sind. Außerdem enthalten Merkmale oft dieselben Informationen und sind daher redundant. Daher sollen im nächsten Schritt die Merkmale bewertet und die besten ausgewählt werden, mit welchen die Klassifikation durchgeführt wird.

Die Analyse der Varianzen (ANOVA) umfasst Methoden zur Untersuchung der Streuung von Variablen in Datensätzen und kann dabei helfen, die besten Merkmale auszuwählen, wie in [7] beschrieben wird. Ziel ist es, Variablen zu identifizieren, die hohe Informationsgehalte über die Klassenzugehörigkeit liefern. Unter Verwendung der Varianzen zwischen den Klassen σ_b und innerhalb der Klassen σ_w kann die Fähigkeit von Variablen, den Datensatz in Klassen zu partitionieren, bewertet werden. Für eine Anzahl von M Klassen C_1, \dots, C_M mit jeweils N_m Trainingsbeispielen pro Klasse wird der sogenannte F -Score berechnet durch:

$$F = \frac{\sigma_b^2}{\sigma_w^2}$$

$$= \frac{\sum_{m=1}^M N_m (\bar{x}_m - \bar{x}) / (M-1)}{\sum_{m=1}^M \sum_{n=1}^{N_m} (x_{mn} - \bar{x}_m)^2 / \sum_{m=1}^M (N_m - 1)} \quad (2)$$

Hierbei ist \bar{x} der Gesamtdurchschnitt und \bar{x}_m der Durchschnitt einer einzelnen Klasse C_m . F gibt den Anteil der Streuung innerhalb der Klassen zur Gesamtvarianz an. Das Ziel besteht darin, eine Gruppe von Variablen mit minimaler Streuung innerhalb der Klassen zu finden und gleichzeitig die Trennung der Klassenmittelpunkte zu maximieren. Nach der Berechnung des F -Scores für jedes einzelne Merkmal können die k Merkmale mit den höchsten F -Scores für die Klassifikationsaufgabe verwendet werden.

Klassifikation

Die besten, aus den einzelnen Segmenten berechneten Merkmale sollen im Anschluss verwendet werden, um eine Klassifikation durchzuführen. Die größte Herausforderung besteht dabei darin, dass die Leckage auch dann erkannt werden soll, wenn sie durch andere Effekte überlagert auftritt. Solche Beispiele sind im (Test-)Datensatz enthalten. Die Merkmale spannen einen k -dimensionalen Merkmalsraum auf, in welchen der Klassifikator nun Entscheidungsgrenzen einzieht, um die Segmente mit Leckage von Segmenten ohne Leckage zu unterscheiden.

Es wurden verschiedene Klassifikatoren getestet, wie z.B. K-Nearest-Neighbor, Entscheidungsbäume, Naiver-Bayes, Quadratische Diskriminanzanalyse, Multilayer-Perceptron und AdaBoost. Die besten Ergebnisse erzeugt in diesem Fall jedoch der Random-Forest-Klassifikator, weshalb dieser Klassifikator kurz vorgestellt wird.

Random-Forest

Ein Random-Forest ist ein Klassifikator, der den sogenannten Ensemble-Lernverfahren zugeordnet wird [8]. Er besteht aus mehreren Entscheidungsbäumen, die jeweils einzeln darauf trainiert werden, das Klassifikationsproblem zu lösen. Entscheidungsbäume sind eine einfache, nachvollziehbare und effiziente Methode, um ein Klassifikationsproblem zu lösen. Allerdings neigen sie zu Überanpassung. Der Random-Forest bildet den Mittelwert über die Klassifikationsergebnisse der unterschiedlichen Entscheidungsbäume.

Ein Entscheidungsbaum besteht aus einem Wurzelknoten, internen Knoten und mehreren Blättern, wie in [20] beschrieben. Jede Klassifizierung beginnt am Wurzelknoten. An jedem Knoten wird basierend auf einem einzelnen Merkmal eine binäre Entscheidung getroffen, ob sein Wert höher oder niedriger als ein Schwellwert ist. Der Schwellwert und das ausgewählte Merkmal sind konstant und werden im Training gelernt, während der Wert

des Merkmals für jeden Abschnitt variiert. Abhängig von der Entscheidung des Knotens wird die nächste Entscheidung basierend auf dem Merkmal und dem Schwellenwert des nächsten Knotens getroffen. Dieser Vorgang wird wiederholt, bis das Ende der Knoten, ein sogenanntes Blatt, das einer Klasse zugewiesen ist, erreicht ist. Normalerweise wird eine maximale Tiefe angegeben, aber nicht alle Zweige des Baumes müssen diese maximale Anzahl von Entscheidungen haben. Die Parameter, die im Training herausgefunden werden müssen, sind die Merkmale eines einzelnen Knoten, anhand welcher unterschieden wird, und ihre zugehörigen Schwellenwerte. Dafür wird der Gini-Index

$$G = \sum_{m=1}^M p_{jm}(1 - p_{jm})$$

verwendet. Für ein gegebenes Merkmal und einen Schwellwert wird die Wahrscheinlichkeit p_{jm} als die Anzahl der Trainingsbeobachtungen mit dem Schwellenwert mit Index j der Klasse C_m definiert. Der Gini-Index ist klein, wenn alle p_{jm} nahe bei 0 oder 1 liegen, was einer schlechten Klassifizierung entspricht. In einem iterativen Prozess wird das Merkmal und der Schwellwert mit dem höchsten Gini-Index am aktuellen Knoten ausgewählt. Um einer Überanpassung vorzubeugen, sollte ein frühzeitiges Abbruchkriterium auf den Entscheidungsbaum angewendet werden. Es ergibt Sinn, einen Mindest-Gini-Index festzulegen. Wenn das Ergebnis darunter liegt, wird ein Knoten als Blatt definiert. Außerdem wird oft eine maximale Tiefe des Entscheidungsbaums festgelegt.

Für einen Random-Forest werden nun mehrere unterschiedliche Entscheidungsbäume trainiert. Jedem einzelnen Entscheidungsbaum wird dabei nicht der gesamte Datensatz zum Training übergeben, sondern nur ein Teil davon. Dadurch sollen sowohl eine Überanpassung als auch identische Entscheidungsbäume verhindert werden.

Einem Random-Forest-Klassifikator ist es damit möglich, die Varianz gegenüber einem einzelnen Entscheidungsbaum stark abzusenken, während die Verzerrung nur minimal vergrößert wird. Dies geschieht aber auf Kosten der Nachvollziehbarkeit des Klassifikators, da durch die unterschiedlichen Datensätze teilweise unterschiedliche und auch gegensätzliche Regeln entstehen. Die Klassifikation eines Datenpunkts dauert bei einem Random-Forest-Klassifikators zwar je nach Anzahl der verwendeten Bäume deutlich länger, ist aber im Vergleich zu anderen Klassifikatoren immer noch sehr schnell.

Ergebnisse

Merkmal	Parameter
Rolloff-Frequenz	90%
Spektraler Kontrast	$q = 5$
Spektrale Bandbreite	-
Fourier Bins	$i = 1, 2, 11, 12, 13, 16$
MFCC	$m = 0, 1, 3, 7$
MFCC - 1. Ableitung	$m = 0, 1, 7$
MFCC - 2. Ableitung	$m = 0, 1, 3, 7$

Tabelle 1: Merkmalübersicht.

Die Ergebnisse sind in Tabelle 1 dargestellt. Zusätzlich wurden die Genauigkeit

$$R = \frac{N_{\text{Korrekt}}}{N_{\text{Gesamt}}} \cdot 100\%$$

der Klassifikation ermittelt und eventuelle Fehlklassifikationen identifiziert. Besondere Schwierigkeiten traten bei der Unterscheidung von Auspuffgeräuschen aufgrund ihrer physikalischen Ähnlichkeit zu Leckagen auf. Zudem stellte sich die Bewältigung der Dämpfung hoher Frequenzen im Zusammenhang mit dem Abstand des Mikrofons zur Leckage als herausfordernd dar.

Anlagenbedingungen	Distanz des Mikrofons	Leckagegröße	Erfolgsrate
Gleiche Bedingungen (keine Störgeräusche)	1,5 m	0 mm, 0,3 mm, 0,45 mm	99.01%
Anlagengeräusche (Anlage bei vollem Betrieb)	1,5 m	0 mm, 0,3 mm, 0,45 mm	91.67%
Wiederkehrende Ventilgeräusche	1,5 m	0 mm, 0,3 mm, 0,45 mm	91.16%
Gleiche Bedingungen (keine Störgeräusche)	1,5 m	0 mm, 0,18 mm, 0,3 mm, 0,45 mm	69.01%
Gleiche Bedingungen (keine Störgeräusche)	1,5 m (hinter der Anlage)	0 mm, 0,3 mm, 0,45 mm	33.33%
Wiederkehrende Ventilgeräusche	1,5 m (hinter der Anlage)	0 mm, 0,3 mm, 0,45 mm	48.75%
Gleiche Bedingungen (keine Störgeräusche)	6 m	0 mm, 0,3 mm, 0,45 mm	33.33%
Anlagengeräusche (Anlage bei vollem Betrieb)	6 m	0 mm, 0,3 mm, 0,45 mm	35.42%
Gleiche Bedingungen (keine Störgeräusche)	10 m	0 mm, 0,3 mm, 0,45 mm	33.33%

Tabelle 2: Klassifikationsergebnisse des Random-Forest-Modells an den verschiedenen Testdatensätzen.

Die Ergebnisse des Random-Forest-Modells wurden anhand verschiedener Anlagenbedingungen analysiert. Dabei zeigte sich, dass das Modell unter gleichen Bedingungen ohne Störgeräusche und einer Mikrophon-Distanz von 1,5 m eine hohe Erfolgsrate von 99,01% für Leckagedurchmesser von 0, 0,3 und 0,45 mm aufwies. Jedoch wurde der Leckagedurch-

messer von 0,18 mm als falsch-negativ klassifiziert, während er bei Anlagengeräuschen oder wiederkehrenden Ventilgeräuschen als falsch-positiv klassifiziert wurden. Zudem wirkte sich die Teilanlage, die zwischen dem Mikrophon und der Leckage platziert war, als Störfaktor bei der akustischen Aufnahme aus und führte zu einer Verringerung der Erfolgsrate. Bei einer größeren Mikrophon-Distanz von 6 m oder 10 m wurde eine Erfolgsrate von 33,33% bzw. 35,42% erreicht. Diese Ergebnisse zeigen, dass das Random-Forest-Modell in bestimmten Szenarien eine hohe Genauigkeit bei der Erkennung von Leckagen aufweist, jedoch Schwierigkeiten hat, genaue Aussagen bei bestimmten Leckagedurchmessern und in Gegenwart von Störgeräuschen zu treffen.

Spektralanalyse

Neben der modellbasierten Signalverarbeitung wurden zwecks besserer Erklärbarkeit aus den Schallvektoren Spektren berechnet und zu Spektrogrammen gestapelt. Im Gegensatz zur Annahme zu Beginn der Untersuchungen sind breitbandige Schallemissionen bis weit in den Ultraschallbereich sichtbar, siehe Abbildung 2 und Abbildung 3. Dargestellt sind Anlagengeräusche mit und ohne Leckage, gemessen in verschiedenen räumlichen Abständen zur Schallquelle. Diejenigen Zeitbereiche mit breitbandigen Emissionen sind auch grafisch gut erkennbar.




Abbildung 2: Spektrogramm erfasster akustischer Signale verschiedener Leckagedurchmesser ohne Einflüsse anderer Geräusche.

Zur Klassifikation ist es vorteilhaft, dass die Anlagengeräusche kaum Ultraschallemissionen enthalten. Mit zunehmender

Entfernung zwischen Messort und Leckageort reduziert sich außerdem die gesamte Schallenergie. Trotzdem werden Leckagegeräusche weiterhin breitbandig erfasst.

erfolgen, die den vorhandenen Daten ähnlich sind, aber verschiedene Variationen und Schwankungen aufweisen. Dadurch kann das Modell robuster und allgemeiner gemacht

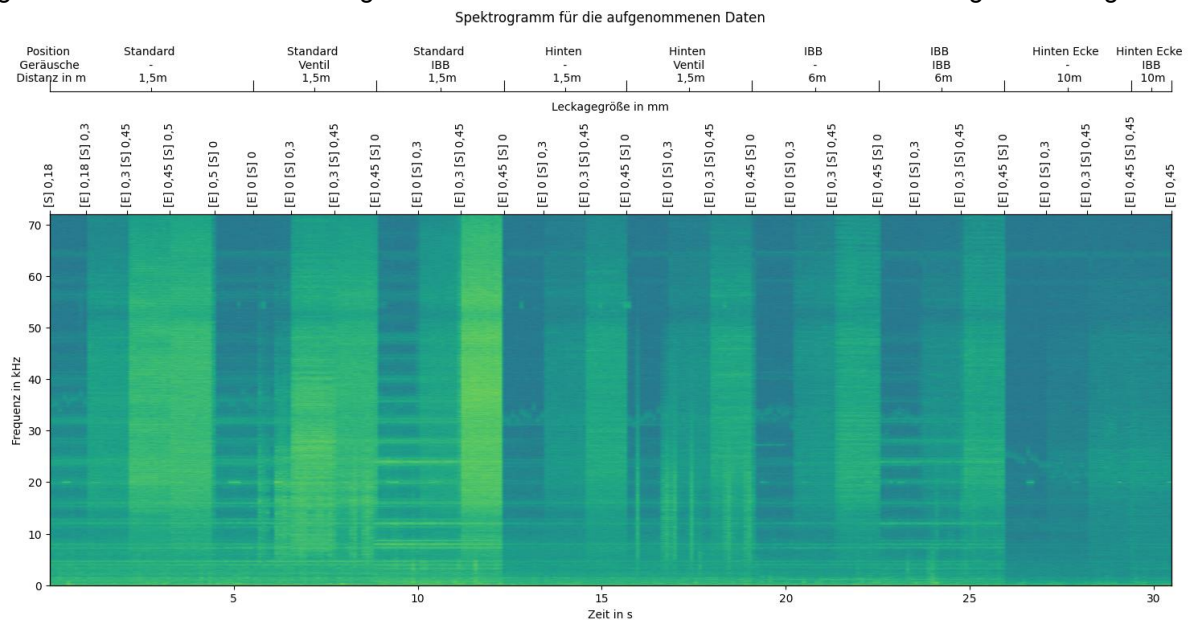


Abbildung 3: Spektrogramm des aufgenommenen akustischen Signals verschiedener Leckagedurchmesser unter Einflüssen von Geräuschen aus der Anlage.

Fazit und Ausblick

Insgesamt kann festgestellt werden, dass das Modell bei bekannten Anlagenbedingungen gut funktioniert und nutzbringend eingesetzt werden kann. Die eingesetzte Methodik ist in der Lage, die Charakteristika von Leckagen in den akustischen Signalen abzubilden, so dass die Erkennung von Leckagen möglich ist. Die Auswahl der Merkmale und des Klassifikators erfordert einigen Aufwand, wobei insbesondere für die Merkmalsauswahl auf bewährte Hilfsmittel zurückgegriffen werden kann.

Um dem Wunsch nach einem umfassend generalisierbaren Tool nachzukommen, sind noch Verbesserungen bei der Übertragung auf andere Anlagenbedingungen erforderlich. Es ist wichtig, die falsch-positiven und falsch-negativen Klassifikationen zu reduzieren, um die Leistung des Modells in realen Szenarien zu verbessern.

Zur Optimierung der Leistung des Leckagemodells können verschiedene Ansätze verfolgt werden. Eine Möglichkeit besteht darin, gezielt Messungen durchzuführen, bei denen keine Auspuffgeräusche vorhanden sind oder mehrere Auspuffgeräusche gleichzeitig auftreten. Dies kann dazu beitragen, das Modell auf solche Situationen besser vorzubereiten und die Klassifikationsgenauigkeit weiter zu steigern.

Eine künstliche Erweiterung des Datensatzes kann ebenfalls dazu beitragen, die Leistung des Modells zu verbessern. Dies könnte durch das Generieren von synthetischen Datenpunkten

werden.

Weitere Daten ohne Leckagen könnten ebenfalls in den Datensatz aufgenommen werden, um eine bessere Unterscheidung zwischen Leckagen und normalen Geräuschen zu ermöglichen. Dies kann dazu beitragen, die Fehlklassifikationen zu reduzieren und die Klassifikationsgenauigkeit weiter zu erhöhen. Darüber hinaus könnten auch andere Ansätze wie LSTM (Long Short-Term Memory) oder neuronale Netzwerke (NN) in Betracht gezogen werden, um die Leistung des Modells zu verbessern. Diese Ansätze sind bekannt für ihre Fähigkeit, komplexe Muster und Zusammenhänge in den Daten zu erkennen und können möglicherweise zu einer höheren Klassifikationsgenauigkeit führen.

Literaturverzeichnis

- [1] D. Gros, „Der Preis der Druckluft,“ Flex-Air, [Online]. Available: <https://flex-air.com/wp-content/uploads/2021/08/Leckage-Flex-Air-Artikel.pdf>. [Zugriff am 13. 04. 2024].
- [2] E. O. Brigham und R. E. Morrow, „The fast Fourier transform,“ *IEEE Spectrum*, Bd. 4, p. 63–70, December 1967.
- [3] M. Kos, Z. Kačič und D. Vlaj, „Acoustic classification and segmentation using

- modified spectral roll-off and variance-based features," *Digital Signal Processing*, Bd. 23, p. 659–674, March 2013.
- [4] D.-N. Jiang, L. Lu, H.-J. Zhang, J.-H. Tao und L.-H. Cai, „Music type classification by spectral contrast feature," in *Proceedings. IEEE International Conference on Multimedia and Expo*.
- [5] A. Klapuri und M. Davy, *Signal Processing Methods for Music Transcription*, Springer US, 2006.
- [6] R. Vergin, D. O'Shaughnessy und A. Farhat, „Generalized mel frequency cepstral coefficients for large-vocabulary speaker-independent continuous-speech recognition," *IEEE Transactions on speech and audio processing*, Bd. 7, p. 525–532, 1999.
- [7] L. St, S. Wold und others, „Analysis of variance (ANOVA)," *Chemometrics and intelligent laboratory systems*, Bd. 6, p. 259–272, 1989.
- [8] G. James, D. Witten, T. Hastie und R. Tibshirani, *An Introduction to Statistical Learning*, Springer US, 2021.