

AIでインフラの異常を見つける

産業技術総合研究所 人工知能研究戦略部 総括企画主幹
村川 正宏



1. はじめに

近年のセンサ技術、通信技術の進歩により、IoT (Internet of Things) とよばれるように、実世界の膨大なセンサデータが容易に取得できるようになってきた。例えば、監視カメラは比較的安価に設置できるようになり、多数のカメラがネットワーク接続され、時々刻々と映像が蓄積されている。またマイクはさらに安価であり、さまざまな機器に組み込み周囲の音響データを取得可能である。さらに、種々のセンサ類もスマートフォン等と組み合わせることで容易にデータを蓄積可能である。

これらのセンサデータは、クラウドサーバ上に蓄積されるのが一般的となっており遠隔地からもチェックすることができるが、すでに人手で確認するには不可能な量となっている。折角データを取得したものの、死蔵されている例も多く聞く。そこでこれらのデータに対して人工知能技術を使って異常を検知することができれば実用的な有用性は高い。取得したセンサデータにおいて何かおかしいことがおきている兆候を自動的に検知することで、人に気づきを与えることができる。その後は、監視員やユーザがその特定されたセンサに対して注意深く経過を観察したり、異常の原因を

調査するフェーズに移行すればよい。

本講演ではこのような人工知能技術を用いた異常検知システムによるインフラ診断支援について、産業技術総合研究所（産総研）人工知能研究センターでの取り組みについて紹介する。以下2章で、データに基づく異常検知システムを外観したのち、3章、4章でそれを適用した具体的な応用事例：風力発電の状態監視、橋梁等の打音検査の高度化、について紹介する。最後5章で、このような取り組みを広く普及する上で、今後必要となるAIの基盤技術について、産総研での検討内容について説明する。

2. データ駆動型異常検知システム

異常検知を人工知能で行う場合には、大きく分けて2種類のやり方がある。ひとつは、正常と異常を区別するための判定基準を、専門家の知識に基づき、判定規則として人間が記述する方式である。基本的には、人間が読める形でのIF-THENルールで記述することが多く、これらを大量にためて3段論法のように推論をすることで異常を判定する。いわゆるエキスパートシステムと呼ばれるシステムであるが、これまでの研究の歴史から人間が明示的に列挙できるルールには限

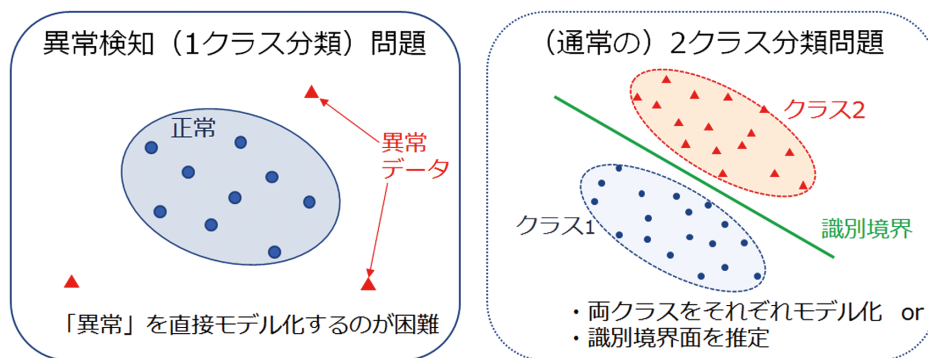


図1 機械学習における異常検知問題の難しさ

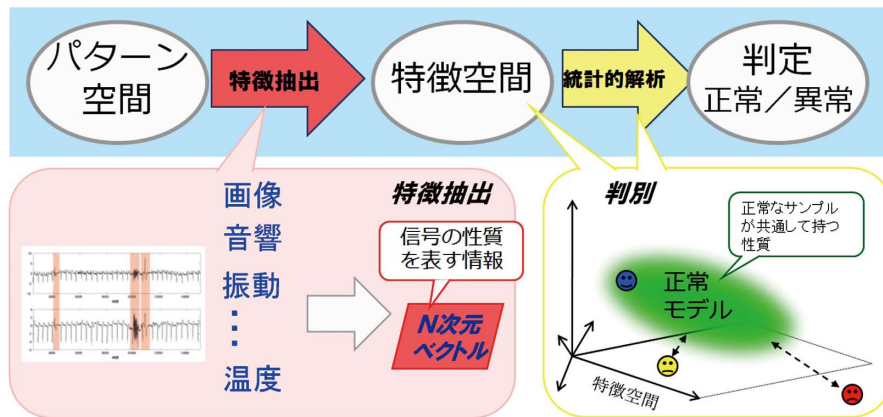


図2 2段階の異常検知の枠組み

りがあって、この知識獲得のボトルネックが実用に供するための課題とされている。

もうひとつのやり方として、データから異常を区別するための判定基準を自動的に獲得する方式がある(以下ではデータ駆動型異常検知とよぶ)。1章で述べたように、膨大なセンサデータが容易に取得できるようになってきたので、これを機械学習技術により解析することで、知識獲得のボトルネックを乗り越えようとする方法である。機械学習にはさまざまな手法があるが¹⁾、一般には教師あり学習と呼ばれる、人間が与えた教師データ(正解ラベル付きデータ)を基にその統計的性質から判別器等の学習を行う。しかし異常検知という問題領域で特に考慮すべきは、得られる教師データの量である。つまり、異常な事例は稀にしか起こらないので、「異常」のラベル付きの教師データはなかなか集まらない(図1)。よって、センサデータからなにが異常であるかを機械学習しようにも、教師データが集まるまでなにもできないことになる。

この問題を回避するために、教師なし学習と呼ばれる学習手法を用いる。この手法では、人間が正解ラベルを与えることなく、得られたデータのすべてもしくは大部分が正常であるとの仮定のもと、機械学習を行う。正常な事例は、センサを設置した場所で大量に得ることができるので、その統計的な性質から「正常」がなにであるかを機械学習すればよい。学習した正常パターンからの逸脱として異常が検出できる。この異常検知の枠組みに関しては、良い教科書²⁾があるので興味がある方はそちらを参照されたい。産総研においては、この「正常」を学習する枠組みに基づき、静止画、動画、音響データなどに適用可能な汎用的な異常検知システムの研究開発を行っている。

このシステムの基本的な考え方は、図2に示すよう

に1段目で汎用的な特徴量を抽出し、2段目で例示から適応学習し、問題に応じて最適な認識処理を行う。1段目では、生のセンサデータの特徴抽出手法により、低次元の特徴ベクトルに変換する。特徴抽出手法については、これまでに様々な手法が開発されてきているが、高次局所自己相関量(HLAC: Higher-order Local Auto-Correlation)と呼ぶ汎用的な特徴量を産総研では1980年代より津が中心となり開発した³⁾。高次局所自己相関に基づく特徴抽出は静止画だけでなく、動画像への拡張(CHLAC)⁴⁾、音響信号への拡張(FLAC)⁵⁾などが行われており、さまざまなパターン信号への適用が可能である。なお近年の深層学習の発展により、こういった特徴抽出のやり方自体もデータから学習的に獲得できるようになっているが、その一般的な説明は本講演では割愛する。

2段目の処理では、1段目で抽出した特徴ベクトルに対して、統計的解析手法を用いる。異常検知の基本的な考え方として、1段目で抽出された特徴量は全空間内のある限定された領域に集中して分布することになる(教師なし学習の「正常」パターンの仮定)。学習フェーズではこの分布をモデル化するが、主成分分析を用いる場合にはこれを部分空間法により近似してモデル化し、正常部分空間とよぶ。ひとたび正常部分空間が得られれば、実際の異常検知フェーズにおいては、検知対象の特徴ベクトルの正常部分空間からの逸脱度を異常検知指標とする。この逸脱度が閾値を超えたときに異常と判定することができる。ここでは主成分分析を用いる手法を例に説明したが、対象とする問題の複雑度によって、混合正規分布モデル、1-class SVMなどの非線形的手法を用いてもよい。

これら2段階の処理からなる異常検知システムは、対象に関する知識やモデルを必要としない点で汎用的

である。また、個別の恣意的な論理判断を用いず統計的手法を用いて総合的に判断しており、情報のロスが少なく頑健な方式となっている。以下ではこのシステムのインフラ診断支援への具体的応用事例を紹介する。

3. 風力発電の故障予兆検知

世界的に再生可能エネルギーの普及が進む中、国内でも「再生可能エネルギーの固定価格買取制度(FIT)」が開始され、風力発電の導入拡大が期待されている。一方で、風車は内部の構成要素が多岐にわたり、専門的な知識と訓練が必要でメンテナンス作業が複雑な点、各種トラブルの発生頻度に対するメンテナンス作業の非効率性、故障要因のトラブルシューティングに多大な人的時間的労力が必要とされるなど、風車運用に関する課題も多い。特に今後は洋上風力の導入拡大が見込まれることもあり、情報技術利活用による遠隔での風車の状態監視システム(CMS: Condition Monitoring System)に対する必要性が高まっている。

我々は、NEDO事業「スマートメンテナンス技術研究開発(分析)」において、機械学習に基づくCMSの高度化を実施した(2013~2017年度)。国内の複数の

事業者にご協力いただき、全国27サイト、43基の風車にCMSを設置させていただき、そこで収集された振動データから異常検知を行った。

本課題における異常検知システム(図3)では、2章で説明した1段階目の特徴量抽出には、FLAC特徴量に加え、従来のRMS値等の典型的な時間領域・周波数領域特徴量を組み合わせて用いる⁶⁾。2段階目の処理としては、混合ガウス分布モデルに基づき、正常状態のモデル化を行う。これは、風車においては正常稼働状態であっても運転条件によってデータが動的に変化するためであり、複数の正常状態をクラスタリングにより教師なし学習でモデル化する。

開発したシステムによる発電機入力部(2013回転/分)に対する異常検知結果例を図4に示す。2015年7月10日付近で逸脱度が正常状態モデル学習時の閾値を継続して超える結果を示しており、本システムにおける異常検知の起点とみなすことができる。実際に7月10日以降の振動データの精密エンベロップ解析によれば、軸受損傷周波数にピークが確認されており、本システムにおける異常検知の逸脱度としても損傷状態を検出できたといえる。実際の現場メンテナンスにおいても8月~9月にかけて異常の兆候が確認されており、

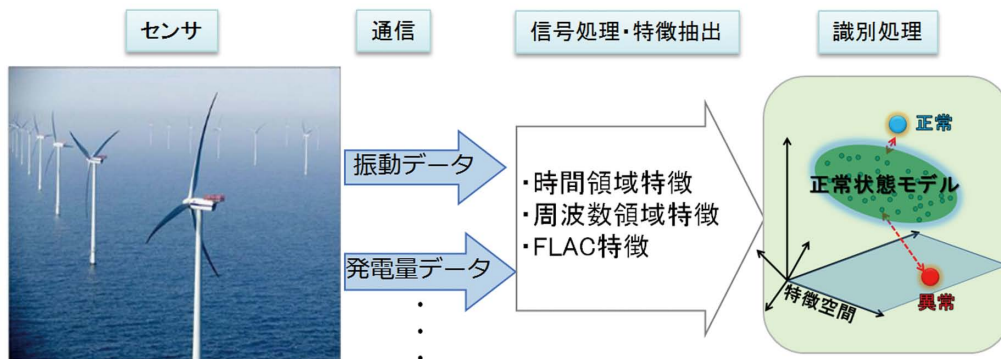


図3 風力発電機(ナセル)に対する異常検知システム

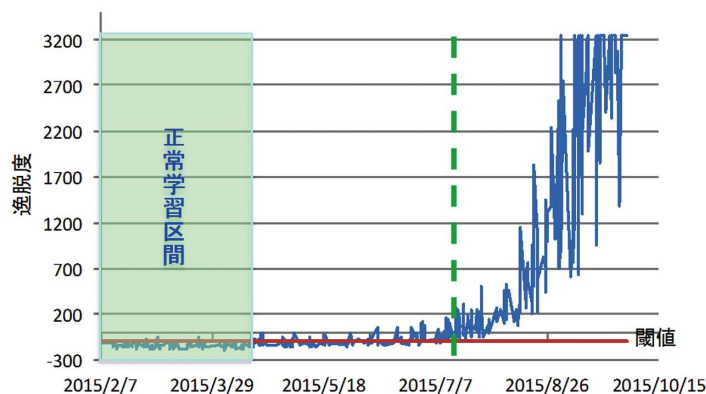


図4 発電機入力部に対する異常検知結果例

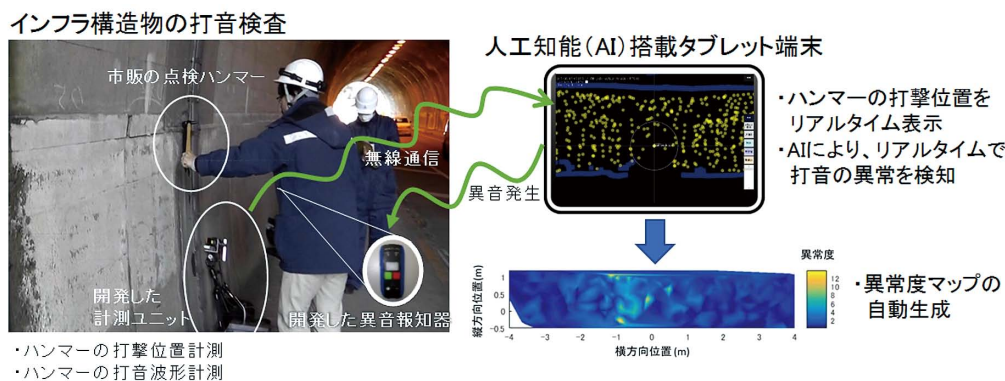


図5 人工知能により打音検査をアシストする「AI打検システム」




図6 実橋梁で得られた異常度マップの例

その後実際に軸受が交換されていることから、早期の異常予兆検知に成功している。また、主軸受(約20回転/分)を対象とした異常検知にも成功している⁶⁾。主軸受のような低速回転機器では、振動実効値に損傷の兆候が明確には現れず、外乱要因としてのノイズの影響も大きいことから、異常検知は難しいとされている。しかし本システムでは従来特徴量のみを用いる場合と比べて、大幅に検出率を向上できている。FLAC特徴抽出により、振動データ中の精密な周波数変化パターンを学習することが可能となったと考えられる。

最終的にCMSを設置した43基の風車において、交換意思決定の1~3ヶ月前での異常予兆検知を実現し、9割以上の異常検知率を達成した。これにより、計画的な部品調達や機材手配が可能となり、故障による風車のダウンタイムを削減し設備利用率向上を実現できる。

4. 橋梁等の打音検査の高度化

近年、社会インフラの老朽化が進み、第三者被害を防止する観点での維持管理方式が重要視されるようになった。そうした中で、国交省により橋梁等の総点検が打ち出され、2020年にかけてインフラの点検需要は急増する。しかしながら、熟練点検員の数は高齢化と労働人口の減少に伴いむしろ減少する傾向にあり、

点検員の確保が難しいケースも見られるようになってきている。この課題に対して我々は、戦略的イノベーション創造プログラム(SIP)「インフラ維持管理・更新・マネジメント技術」で、学習型打音解析技術の研究開発を行い(2014~2017年度)、点検員の技術に左右されず正確に損傷の検出が可能な打音検査技術の開発を目的とした。この目的達成のためにSIP事業では、(1)打音解析手法の開発(2)打音装置および打音解析システムの開発(3)打音データセット構築と性能評価、で研究開発を行った。

一般的な打音検査においては、検査員は検査ハンマーを用いてコンクリート構造物を打撃し、その打撃音を聞いて、その構造物の状態を判断している。これは、検査員の経験や感覚に依存することになり、その検査結果が検査員によってバラツキやミスが生じる可能性がある。一方、インパクトエコー法は、1980年代に提案され、コンクリート構造物の非破壊検査手法として多く使われてきた。一般的な定義として、インパクトエコー法ではハンマー等による打撃がコンクリート構造物の表面に加えられる。その後、打撃点付近に設置されたセンサによって、打撃によって引き起こされ構造物内を伝播してきた衝撃波を計測する。その計測された信号をフーリエ変換によって周波数領域において調査することで、コンクリートの状態が評価される。従

来は打音のスペクトルの卓越周波数のみがコンクリート状態評価の指標(特徴量)として使われることが一般的であった。しかしながら、単一の特徴量のみを使うだけでは、ノイズの影響を受けやすいうえ、その他の特徴を捨ててしまっていることになる。そこで本研究では、2章で説明したような機械学習技術で打音の解析を行うアプローチで、より正確な欠陥検出を目指した。

このように機械学習技術を打音解析に適用しようとした場合、一番大きな課題としては、2章で説明したように学習対象となる打音データが十分に集まらない点にある。コンクリート構造物の材質の違いや、打撃ハンマの種類の違いなどを考慮すると、すべての組み合わせを網羅的に収集するには工数がかかる。そのため、データが集まるまで学習ができない、もしくは、データが集まらなかった欠陥の種類については、誤って正常と判定してしまうという問題点が生じる。

そこで我々の解析手法においては、2段階の学習的手法で損傷を推定するアプローチをとった。1段階目では、取得した大部分の打音は正常であるという仮定のもと、検査対象ごとに正常パターンを統計的に学習させる(教師無し学習)。学習した正常パターンから逸脱したものを欠陥の疑いありと検出する。これにより、さまざまな種類の打音データが集まらなくとも、まずは欠陥の有無を判断することができ、対象物の種類によらない汎用的な手法となる。2段階目では、1段階目の判定結果に熟練者による教師ラベルをつけて蓄積し、蓄積した結果をもとに判別学習を行う(教師有り学習)。

これにより欠陥検出の精度を向上できるようになる。

システム開発では、点検ハンマによる打音の違いを機械学習し、構造物の異常箇所と異常の度合いを自動検知する「AI打検システム」を開発した(図5)⁸⁾。検知結果を点検員にリアルタイムで提示し、レーザー光による測域センサで人手によるハンマの打撃位置を簡便に取得し、打音解析結果と統合することで異常度マップを自動的に作成できる。性能評価においては、打音採取実験とそれの正常異常の正解ラベルをつけたデータセット構築、およびそれを用いた性能評価試験を行った。試験では、人力による詳細な叩き点検を実施し内部欠陥(浮き)が確認された7つの実橋等に対して、AI打検システムによる点検を実施し、その結果の比較を行った。大まかなブロック単位ですべての場所で欠陥の見落としが無く、また打音1音ごとの正答率は、最高で93.2%、平均で84.0%という良好な結果を得た。AI打検システムを用いた点検作業フローを検討し、現地作業での実測値を用いて比較した結果、従来手法より1~2割程度の時間増加となったが、本システムでは検査結果が点検員の技量に依存せずコンター図が得られる、等のメリットが得られる。解析の結果得られた異常度マップの例を図6に示す。異常度マップでは、黄色が異常度の高い打音、青色が健全な打音の部分を示す。左側の写真には、人力による詳細な叩き点検を行った範囲(黄枠内)と損傷が認められた範囲(赤枠内)を示している。この写真と異常度マップを比較すると、損傷範囲が大体一致していることが分かる。

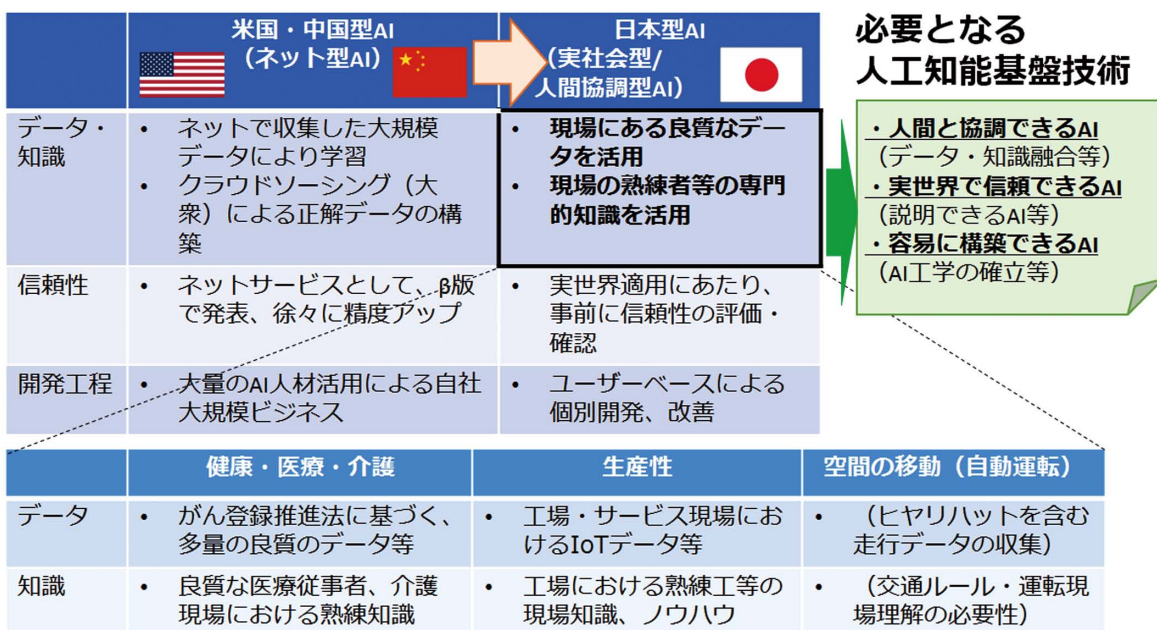


図7 日本型AIの目指すべき方向性

5. 今後必要となるAIの基盤技術

産総研人工知能研究センターでは、今後日本で取り組むべきAIの基盤技術として、以下のような方向性を打ち出している⁹⁾。これまで、機械学習、深層学習等の第三次ブームの人工知能技術は、インターネット上のサービスでビッグデータを収集し、学習してサービスを向上させるネット企業がけん引してきた。しかし、今後AIの利活用分野が、IoTやロボット等を用いた実世界のサービスへと広がる中、現場のデータ・知識に関して日本が強い分野(生産性、健康・医療/介護、空間の移動など)で必要とされる人工知能基盤技術に取り組むべきではないかと考えている。具体的には図7に示したように、「人間と協調できるAI」「実世界で信頼できるAI」「容易に構築できるAI」の3つの方向性を検討している。

これらの方向性について、これまで説明してきたインフラ診断支援の事例に即しながら、講演では現在進行中の研究事例も交えながら説明する。ここでは、それぞれの問題意識について述べる。

- ①「人間と協調できるAI」：熟練者も含む人間の知識を構造化し利用しやすくすることが難しい上、構造化された知識をデータとあわせて利用する機械学習手法が未確立である。その結果、情報が不完全(得られるデータが少ない、欠測が多い、稀なイベントのデータが無い)で複雑な実世界への対応ができていない。
- ②「実世界で信頼できるAI」：想定しきれない状況が実世界では起こりうる。しかし、機械学習がどの範囲で、どの程度有効なのか評価する手法が存在せず、AIの製品化時に一定の品質を担保できない。また機械学習の判断根拠が分からず、リスクの高い応用に安心して使えない。
- ③「容易に構築できるAI」：データエンジニアが慢性的に不足する中、AIの開発手順には試行錯誤が伴い、多くの無駄が生じている。また、開発したAIをモジュール化し公開したり、再利用するための技術が十分でない、など。

以上、産総研人工知能研究センターで研究開発を行っているインフラの異常検知システムの事例を紹介した。本講演で紹介した分野以外にも、異常検知は産業応用の裾野が非常に広い技術である。一方で機械学習という観点では、教師データの正常例と異常例がアンバランスに得られるという特徴的な性質をもつ問題

領域である。まだ学問的にも発展途上であり、最新の研究成果を実応用に即時投入できる面白さがあり、今後多くの技術者の参入を期待したい。

参考文献

- 1) C.M.ビショップ：パターン認識と機械学習(上・下)，丸善出版，2012
- 2) 井出剛：入門 機械学習による異常検知，コロナ社，2015
- 3) 大津展之：適応学習型汎用認識システム：ARGUS, Synthesiology, Vol.4, No.2, pp.70-79, 2011
- 4) Kobayashi,T. et al., "Action and simultaneous multiple person identification using cubic higher order local auto-correlation," presented at the 23rd International Conference on Pattern Recognition, Cancun, Mexico, December 4-8, 2004, pp.741-744.
- 5) Ye,J. et al., "Audio-based sports highlight detection by Fourier local auto correlation," presented at the 11th Annual Conference of the International Speech Communication Association, Makuhari, Japan, September 26-30, 2010, pp.2198-2201.
- 6) Ogata,J. et al., "Development and evaluation of vibration-based anomaly detection system using actual wind turbine data," presented at the 15th World Wind Energy Conference and Exhibition, Tokyo, Japan, October 31-November 2, 2016, Paper C-1-6.
- 7) 長谷川隆徳他：正常・損傷の表現学習に基づく風力発電システム異常検知技術の高度化，第39回風力エネルギー利用シンポジウム，December 6-7, 2017, pp371-374.
- 8) 産業技術総合研究所 プレスリリース：人工知能を用いた打音検査で点検漏れを防止する装置を開発，2017年6月1日。
- 9) 産業技術総合研究所人工知能研究戦略部：日本が取り組むべき今後のAI基盤技術の方向，https://www.airc.aist.go.jp/info_details/docs/180523/ai_strategy180523.pdf，2018年5月23日。