

社会インフラ保守の効率化を実現する自律進化型無線センサネットワーク構成技術の研究

代表研究者 枚田 明彦 千葉工業大学 工学部 教授

1 はじめに

日本では、高度経済成長期に建設された社会インフラの老朽化が進んでいる。今後社会インフラの維持管理・更新費は急増し、インフラ施設を維持する費用が2015年度から54年度の40年の総額で547兆円に及ぶと試算されている[1]。しかし、財政難、点検員の高齢化等から、保守・点検にかかるリソースを大幅に増やすのは困難であり、維持管理の効率化が必要である。

維持管理の効率化のポイントとしては、以下の3点があげられる。

- ① 単に点検するだけでなく、あとどのくらいもつのかという診断を行う、ということ、
- ② 異常が発生したらすぐわかるように、センサで常時監視を行うこと
- ③ 点検員が現場に行かなくても、遠隔から自動でのデータ収集、診断を行えるようにすること

このような背景のもと、日本政府では、インフラ保守の効率化を実現すべく、2020年までに重要インフラの20%にセンサ等の利用による補修・点検を実施することを検討している。政府の見積もりでは、センサの利用により、50年で24兆円の更新費削減効果が見込まれている。既に、橋や道路などの社会インフラにセンサを設置し、これらの構造物を遠隔から常時モニタリングを行う取り組みが進められている。例えば、平成24年に完成したゲートブリッジには、歪センサ、変位センサ、加速度センサなど、複数のセンサが建設時に設置され、遠隔から橋の健全性を常時モニタリングするシステムが実運用されている[2]。

但し、インフラの保守・管理を行うセンサネットワークを実現するためには、多くの課題がある。

第1の課題が、屋外インフラ設備には、センサに給電する電源線やデータを収集する通信線が準備されていないことである。このため、インフラ用センサは電池で駆動する必要があり、かつ、データの収集には無線通信を使用する必要がある。但し、これらの無線センサ端末のメンテナンスは、現状のインフラの点検周期より長くなければ意味をなさないため、5年から10年以上、電池を交換することなく、メンテフリーで動作し続けることが求められる。即ち、無線センサ端末の通信方式やセンシング方式、信号処理などにより、無線センサ端末の省電力化を極限まで追求する必要がある。

第2の課題は、インフラに設置するセンサの数およびセンサが出力するデータ量が膨大になるということである。特に加速度データをモニタリングする場合、サンプリング周波数は1kHz程度になってしまうため、1日で膨大なデータが出力される。無線センサ端末が高密度に配置された場合は、各端末が出力するパケットが衝突し、通信の輻輳が生じる。

第3の課題は、インフラ構造物の何をセンシングすれば、安全が担保されるのかが、確立されていないことである。

このような課題が存在するため、無線センサネットワークによるインフラ構造物の遠隔常時監視による維持管理の効率化は、一部の重要インフラを除いては実現されていない。

本研究は、センサデータを機械学習で解析し、データが持つ重要性を自動判別し、センサ構成・ネットワーク構成を自律進化させる技術の開発を行う。具体的には、機械学習により、測定対象の特徴抽出に必要なデータを同定し、そのデータを選択的に抽出して、ネットワークに送出する無線センサ端末の研究を行う。最終的には、機械学習により、各センサが出力するデータの重要度を判別し、重要度に応じて、マルチホップ無線通信におけるルート割当の最適化を実施することにより、真に必要なデータを最適の無線リソースで伝送できるネットワーク構成法の検討を行う。

2 無線センサネットワーク構成技術

2-1 線形予測分析（LPC 分析） & 機械学習による構造物劣化検知技術

構造物にセンサを設置して建物や橋梁、水道管などの構造物を遠隔・常時監視し、構造物の健全性を診断する研究開発が活性化している[3]。機械学習の技術の進展により、大量のセンサ出力データを機械学習により解析することで、構造物の健全性の診断の精度を上げる検討も進められている。NTTアドバンステクノロジーは、水道管に設置した音響センサの出力を機械学習により解析することにより、漏水の有無を自動識別することに成功した[4]。通常、橋や建物などの構造物の健全性の診断には、加速度センサの出力をフーリエ解析やwavelet 解析を実施し、特定した固有振動数の変動等を解析する手法がもちいられている [5]。しかし、外力による振動が与えられない構造物においては、微細な振動しか生じないため、従来のフーリエ変換などによる解析では、機械学習による診断の精度があがらないという課題があった。

本研究テーマでは、構造物の劣化を診断する手法として、加速度センサで測定した構造物の固有振動数を線形予測分析（LPC 分析）により解析し、その結果を教師データとして機械学習にかけることにより、構造物の健全性の診断が可能か検討した。

線形予測符号は、離散信号の将来の値をそれまでの標本群の線型写像として予測する数学的操作である。LPC では時間的に移動している複数のピークであるフォルマントを予測し、その効果を信号から除去し、残った部分の強さと周波数を予測することで信号を分析する。音声などのスペクトル情報などを、極めて少数のパラメータで能率的かつ正確に表現可能である[6]。LPC を用いると、与えられた信号の周波数スペクトルの概形（スペクトル包絡）を求めることができる。信号を識別するうえでスペクトル包絡のピーク（フォルマント）の位置や形状は重要な手がかりを与える。本研究では、算出した 30 次の LPC スペクトラムのケプストラムを求め、それらのケプストラムを教師データとして、機械学習による学習分類を実施した。ケプストラム解析では、時間波形から LPC パワースペクトラムを算出し、そのスペクトラムデータを波形とみなしてそれを FFT を行う。ケプストラム分析により、スペクトラムの周期情報の抽出 やスペクトラムの包絡線の検出が可能になる [7]。本研究における解析の手順を図 1 に示す。

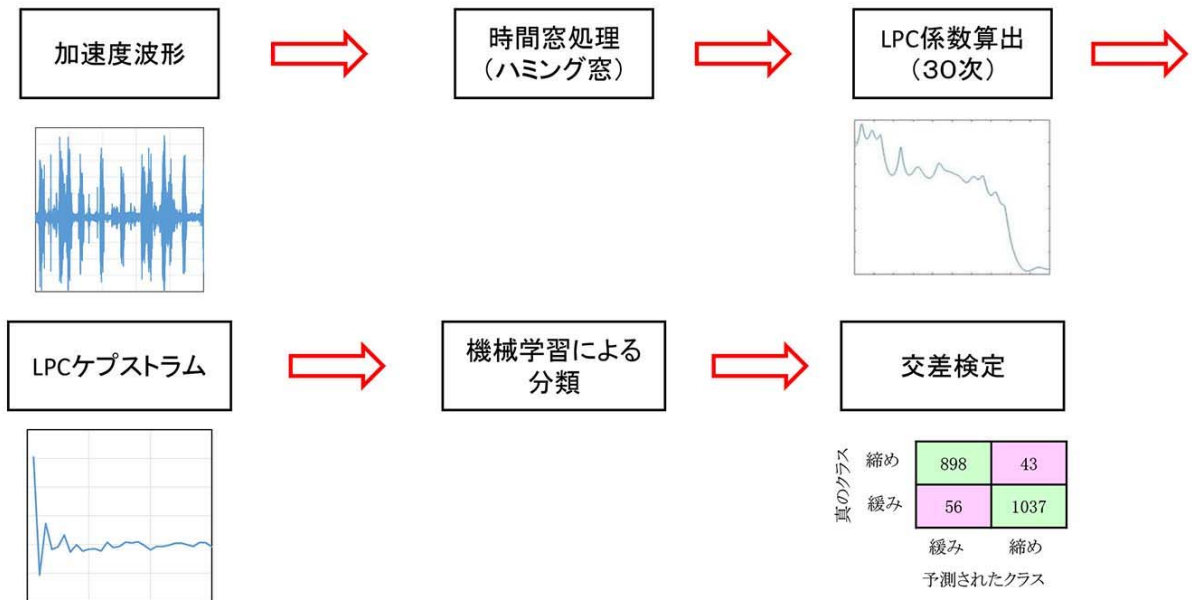


図 1 本研究における加速度データの解析手順

本研究では、インフラ構造物として、千葉工業大学 6 号館屋上に設置された風力発電設備を対象に、センサデータの機械学習解析による健全性の判別の可能性を検討した。具体的には、風力発電設備の支柱にネジをとりつけ、支柱に取り付けた加速度センサの出力を機械学習で解析することにより、そのボルトの緩みの

有無を自動判別が可能か検討した。図2に、設置した風力発電設備および使用した加速度センサを示す。使用した加速度センサは、セイコーエプソン社製 M-A550AR20 である。本センサは屋外インフラ計測用の、Q MEMS 技術によってつくられた加速度センサであり、センサの分解能は $0.06 \mu\text{G}$ 、計測帯域は 100 Hz 、最大のサンプリング周波数は 1000 Hz である。本センサは、防水 RS-422 ケーブルにより PC と接続することによって、PC に記録される。風力発電設備に設置した加速度センサの出力の一例を図3に示す




図2 本研究で使用した風力発電設備および加速度センサ




図3 加速度センサの出力データ

はじめに、取得したY軸の加速度データに対して、高速フーリエ (FFT) 解析を実施した。FFT解析には、MATLAB を利用した。取得した加速度データをFFT変換した結果を図4に示す。加速度センサのサンプリング周波数は 1000 Hz であり、FFT 解析では、10 秒 (10000 点) の窓関数を使用した。各フレームのオーバーラップは 2000 点である。20~30 Hz 付近および 50~70 Hz 付近に強いピークが観測される。しかし、これらのピークは風力発電設備の風車の回転に起因する振動であり、風速の変動に依存して周波数が変動している。

つぎに、各フレームで得られた各スペクトルのピークの強度及び周波数をパラメータとして、ネジの緩みを機械学習により自動判別可能か検討を行った。但し、風がなく、風車が揺れない状況では、支柱の固有振動数やボルトの揺れも生じないため、機械学習の教師データとしてはふさわしくない。そこで、各フレームごとに得られたスペクトルのピークの最大強度が一定値以上になったスペクトラムを揺れが生じた状態として、そのスペクトルを抽出して機械学習にかける作業を行った。各窓関数に対応するスペクトルに現れるピークのなかで、周波数が $0 \sim 100 \text{ Hz}$ の範囲において、ピーク強度が上位 20 のピークについて、そのピーク強度とピーク周波数をパラメータとした教師データを作成し、機械学習による分類を実施した。分類の精度は5分割の交差検定により算出した。しかし、この解析手法では、分類学習器にバギング決定木 [8] を使用した場合、78.4%の精度が得られたが、これ以上の精度は得られなかった。これは、周波数が $0 \sim 100 \text{ Hz}$ の範囲において、強度が上位 20 のピークを選択すると、上述した風力発電設備の風車の回転に起因するピークのみを選択しており、風力発電設備の支柱の固有振動やボルトの緩みに起因する振動は、機械学習のパラメータとして選択されなかったためと考えられる。

支柱の固有振動やボルトの緩みに起因する振動のピークを機械学習の教師データとして利用できるようにするため、パラメータとして利用するピークの手順を以下のように変更した。0 Hz から 100 Hz の範囲を 5 Hz 刻みの 20 個の周波数帯に分割し、選択した 5 Hz の周波数範囲の中で、スペクトラムのピークの強度が最も強い上位 2 つのピークの強度の値と周波数値を機械学習の教師データのパラメータとして使用した。各 5 Hz の周波数帯ごとに、2 つのピークの値および 2 つの周波数の計 4 つのパラメータを利用するため、各フレームで得られたスペクトルごとに、 $4 \times 20 = 80$ 個のパラメータを設定することになる。これらの教師データのパラメータを分類学習器にアンサンブルバギング決定木を利用して解析した結果、92.3%の精度で、ボルトの緩みの有無を判別できた。

次に、どの周波数帯のピークが機械学習の精度に影響を与えるかを明らかにするため、20 個の周波数帯のうち、1 つの周波数帯を教師データのパラメータから外した場合の精度を求めた。指定した周波数帯のパラメータを外して機械学習を行った結果、精度が低下した周波数帯の結果を表2に示す。10-15 Hz の周波数帯

のパラメータを外して解析した場合、精度は 88.8% と最も低下した。この結果は、10-15 Hz の周波数帯に、ボルトのゆるみを判別するうえで最も重要なピークが存在していることを示している。図 5 に 10-15 Hz の周波数スペクトラムを示す。13 Hz 付近、および、15 Hz 付近に明確なピークが見られる。このピークは複数のフレームで算出したスペクトラムで同一の周波数に現れているので、このピークは風車の回転による振動に起因するものではなく、支柱の固有振動やボルトの緩みに起因する振動のピークと考えられる。但し、ピーク強度は、20~30 Hz 付近および 50~70 Hz 付近観測される風車の回転に起因するピークと比較すると強度ははるかに小さい。このため、0~100 Hz において、ピーク値の強い上位 20 のピークを選択すると、この 10-15 Hz のピークは含まれていないため、上位 20 のピークをパラメータとして選ぶ手法では、分類の精度が向上しなかったと考えられる。最後に、20 の周波数帯のうち、表 2 に示した 7 つの周波数帯のみを機械学習の教師データのパラメータとして解析した結果、93.8% の精度が得られた。




図 3 加速度センサの出力データの F F T 解析結果

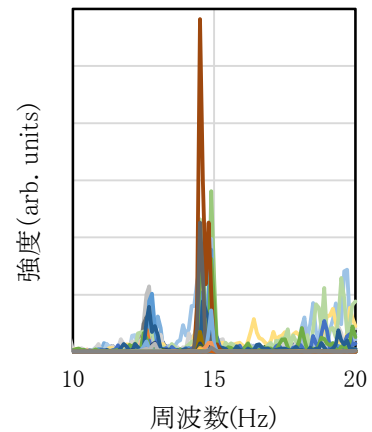


図 4 図 3 に示すスペクトルの 10-20 Hz の帯域の拡大図

パラメータから外した周波数帯	精度	パラメータから外した周波数帯	精度
10-15Hz	88.80%	80-85Hz	91.90%
25-30Hz	91.20%	85-90Hz	91.50%
50-55Hz	91.90%	90-95Hz	91.90%
65-70Hz	90.40%		

表 2 20 個の周波数帯のうち、1 つの周波数帯を教師データのパラメータから外した場合の機械学習による分類の精度

次に、加速度データの L P C ケプストラムを機械学習のパラメータとして利用した場合、F F T 解析と比較して機械学習の精度が向上するか検討を実施した。F F T 解析と同様、加速度センサのサンプリング周波数は 1000 Hz であり、1.024 秒 (1024 点) のハミング窓を使用した。ハミング窓のオーバーラップは 0.512 秒 (512 点) である。L P C 分析はスペクトル包絡を求める手法であり、ケプストラム分析より信号のピークの形状をより強調した包絡線が得られる。L P C では、過去の信号から未来の信号を以下の式で予測する。

$$\hat{x}(n) + \sum_{i=0}^p a_i x(n-i) = e(n)$$

a_i は線形予測 (LPC) 係数であり、実際の観測値から誤差 $e(n)$ を最小にすることで推定可能である。本研究では、ハミング窓により切り出された加速度データに対して、30次のLPC係数を求める。算出した30次のLPC係数を用いて、LPCスペクトラムを計算した結果を図5に示す。風速の変動に従い、揺れが生じている時間帯と揺れていない時間があることがわかる。また、FFT解析の結果と同様、20~30 Hz 付近および 50~70 Hz 付近に強いピークが観測される。次に、通常のFFT信号のケプストラム分析と同様、LPCスペクトラムに対して、LPCケプストラムを算出した。結果を図6に示す。このLPCケプストラムの3次の次数を使用して、風力発電設備で揺れが生じてる時間を抽出した。

抽出したLPCケプストラムの30次の次数を機械学習の教師データの次数として利用し、機械学習による分類を実施した。学習分類器には、Support Vector Machine (SVM)を利用した [9]。5分割交差検定による分類の精度の結果を表3に示す。ボルトが「締めた状態」で計測した加速度データ全941個の内、898個のデータを「締めた状態」と正しく分類し、43個のデータを「緩んだ状態」と誤って分類した。また、ボルトが「緩んだ状態」で計測した加速度データ全1093個の内、1037個のデータを「緩んだ状態」と正しく分類し、56個のデータを「締めた状態」と誤って分類した。データ全体では、95.1%の精度で、ボルトの緩みの有無を判別できた。この値は、FFT解析の結果を機械学習により分類した際の精度93.8%より高い値となった。これらの結果より、FFT解析と比較し、LPCケプストラム解析したデータを教師データとして機械学習を実施した方が、分類学習の精度がより高くなることを実証した。

今後は、LPCケプストラム分析やSVMにおける各種のパラメータを最適化することで、分類精度の向上を行う予定である。さらに、計測時間を増やして加速度データのサンプルを増やす事により、分類学習器の精度を向上を図るとともに、ボルトの緩みに関しても、様々な緩みの状態を設定して実験を重ねることで、様々な劣化の状況を判別可能にする分類学習器の構築を目指す。




図5 加速度センサの出力データのLPCスペクトラム

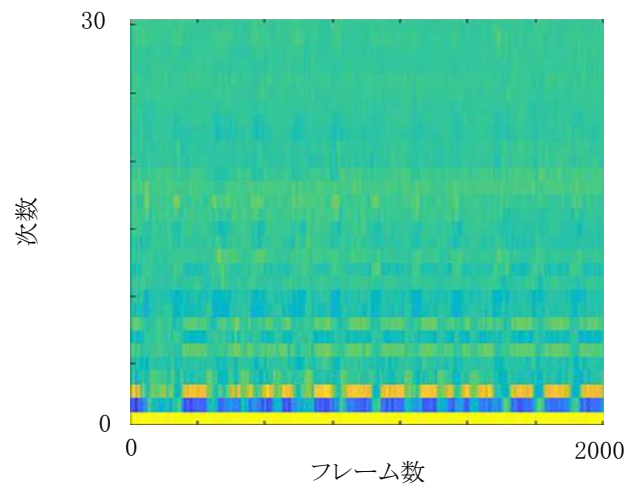


図6 加速度センサの出力データのLPCケプストラム

真のクラス	締め	898	43
	緩み	56	1037
		緩み	締め
		予測されたクラス	

表3 LPCケプストラムの機械学習による分類の混合行列

2-2 機械学習サーバとの連携によるイベントドリブン型ネットワーク構成技術

2-1 節に記載したように、本研究に使用した加速度センサは、サンプリング周波数が 1000 Hz であるため、1 日連続で動作させると、10 Gbyte を超えるデータが出力される。これらの全てのデータを無線で伝送すると、データ送信に電力が消費され、電池の寿命が短くなってしまうため、送信データ量の削減が求められる。

そこで、我々は、次のような無線センサ端末を提案している。この無線センサ端末は、設置当初は、センサ（加速度センサ）が出力した信号をサーバで全解析し、検知すべき信号を機械学習により同定する。同定した結果をもとに、検知すべき信号のみを出力するよう、無線センサ端末内の回路をネットワーク側から調整する。この結果、設置したセンサが、測定対象の特徴抽出を検知するために必要なデータのみ送出手になるため、センサがネットワークに送出するデータ量が時間とともに小さくなり、無線送信に必要な消費電力が減少していく。2-1 節の検討結果に示すように、風力発電設備に設置したボルトの緩みの有無の判別を機械学習により解析した結果、13~15 Hz 付近の周波数がボルトの緩みの有無の判別に非常に重要であることを示した。即ち、全センサ出力の中から、機械学習によって、検知すべき信号（周波数帯）を同定したことになる。

そこで、本節では、次のステップである「検知すべき信号のみを出力するよう、無線センサ端末内の回路をネットワーク側から調整する」機構について検討を行った。具体的には、加速度データの中から、ボルトの緩みの有無の判別に重要な周波数帯である 13~15 Hz 付近の信号を切り出すフィルタについて検討を行い、そのフィルタを使用した場合、送信データ量がどのくらい低減可能か検討した。但し、今回実験で使用した風力発電設備において、ボルトの緩みの有無の判別に重要な周波数帯は 13~15 Hz であったが、他の型式の風力発電設備、あるいは、他の型式のボルトの場合には、健全性の判別に重要となる周波数帯は異なる可能性がある。そこで、機械学習により同定された検知すべき信号に応じて、切り出す周波数帯を変更できるよう、可変フィルタの検討を行った。

当初は、印可する電圧により容量値を変更可能なキャパシタとなるバラクタダイオードを使用したアナログ回路による可変フィルタについて検討を行った。しかし、10~20 Hz の周波数帯で通過帯域を制御することを可能にする可変容量幅を有するバラクタダイオードが入手できないことが判明した。このため、デジタルフィルタでの信号処理を行うこととした。デジタルフィルタとしては、低域カットオフ周波数が 10 Hz、高域カットオフ周波数が 20 Hz である 30 次のバンドパス FIR フィルターを設計した。図 7 に、設計したバンドパスフィルタの特性を示す。

図 8(a) に示す風力発電設備に設置した加速度センサの出力データをこのデジタルフィルタにより信号処理した結果を図 8(b) に示す。デジタルフィルタによりノイズが除去されており、無振動時のノイズレベルの 2 倍の強度のシグナルが得られたポイントをフィルタリングの前後でカウントすると、フィルタリングによりポイント数が約 1/60 に減少した。

本結果により、適切なフィルタの導入により、センサからネットワークに出力するデータを大幅に圧縮することができる見通しを得た。




図 7 設計したデジタルフィルタ




図 8 (a) 風力発電設備に設置したセンサの出力データ
(b) デジタルフィルタ後の波形

2-3 自律的に進化するネットワーク構成技術

日本において、電柱の数は平成24年の時点で約3500万本の電柱が設置されている。設置年数が50年を超える電柱も多数存在するため、これらの多数の電柱を遠隔から常時観測するニーズが高まっている。電柱は、道路沿いに、道路の片側、あるいは、両側に20~30mm間隔で設置されている。本研究テーマでは、この電柱をモデルに、規則的かつ高密度に配置された多数の無線センサ端末での最適なマルチホップ無線ネットワーク構成法を検討する。

センサネットワークの伝送特性のシミュレーションには、SCALABLE Networks社製のネットワークシミュレータ Qualnet を利用した。ルーティングプロトコルとしては、AODV (Ad hoc On-Demand Distance Vector) プロトコルおよび OLSR (Optimized Link State Routing) プロトコルを採用した。AODV は Reactive 型ルーティングプロトコルの一種であり、要求があったときのみ (オンデマンドで) 経路を確立する [11]。OLSR は Proactive 型のルーティングプロトコルである。経路は通信を行なう前に確定されており、いつでも直ちに通信を開始することができる [12]。

図9に Qualnet 上で構築したセンサネットワークのモデルを示す。第1のモデルは、道路沿いに電柱が20m間隔で100本配置されている。終点となるノードの番号を「1」とし、20m間隔で並んだノードを、終点から近い順に、ノード番号を「2」、「3」、...「100」のように定める。第2のモデルでは、道路を挟んで20m間隔で設置された電柱を道路の両側に100本ずつ配置した構成となっている。終点と同じ列のノードのノード番号は、モデル1と同じである。また、終点が含まれない列のノード番号は、終点に近いノードから、「101」、「102」、「103」、...「200」と定める。「2」~「100」、または、「2」から「200」のノードは、終点であるノード「1」に向けて、データを送信する。標準条件では、各ノードが1回あたり送信するデータパケットのサイズは512byte、送信間隔は10秒である。また、シミュレーションした時間は2時間である。




図9 電柱に設置したセンサノードで構成される無線センサネットワークの模式図

図10に、ルーティングプロトコルに OLSR を使用した際の、各ノードが送信した送信データの総量に対する終点であるノード「1」が受信した総受信データ量の割合である受信率のノード依存性を示す。ホップ数が12以下の場合、各ノードから送信したデータのコーデインータにより受信されたデータの割合である受信率は100%となったが、ホップ数が12を超えると、ホップ数の増加に伴い、受信率が低下した。ホップ数が49の場合(ノード番号「50」)の受信率は約33%、ホップ数が99の場合には約7%となった。電柱が1列の場合と2列の場合を比較した場合、1列の場合にはホップ数が12から25に増加すると急激に受信率が低下し、約65%となっているのに対し、2列の場合には、ホップ数が25の場合でも80%を超える受信率となっている。これは、2列になったことで、選択可能なルートが増えた結果、受信率が向上したと考えられる。

図11に、ルーティングプロトコルを AODV に変更した際の受信率のノード依存性を示す。AODV では、ホップ数が1を超えると、受信率が100%を割り込み、ホップ数が増加すると、OLSRと比較して、急激に受信率が低下し、ホップ数が12の場合で受信率は約12%となった。さらに、ホップ数が67を超えると受信率が0%となった。

インフラ構造物のセンサネットワークによる維持管理では、大半の構造物は健全であるため、きめ細かくセンシングを行い、そのセンシングデータをネットワークで伝送する必要はない。しかし、2-1節で示したように、センシングデータの機械学習による解析により、劣化の予兆がとらえられた構造物が少ない割合ではあるが存在した場合、その構造物は出来るだけ短い間隔で精密にセンシングを行う必要がある。このような

シナリオを想定して、100本の電柱のうち、1本だけが劣化した電柱として、他の健全な電柱より大きなデータを送信するモデルを仮定して、各ノードが送信したデータの受信率を解析した。結果を図12に示す。終点から49ホップ目のノード「50」のみ、1回あたりのデータ送信量を10000byteにした場合、他のノードが送信したデータの受信率は大きな変化は見られなかった。一方、ノード「50」が送信したデータの受信率は33%から5%と大幅に低下した。また、ノード「50」のみ、送信間隔を10秒から1秒にした場合、他のノードの受信率、および、ノード「50」が送信したデータの受信率はほとんど変化しなかった。AODVについても同様の検討を行ったところ、ノード「50」の標準条件での受信率は4.3%であったのに対し、1回あたりのデータ送信量を10000byteにした場合の受信率は1.4%と低下した。一方、送信間隔を10秒から1秒にした場合、ノード「50」が送信したデータの受信率はOLSRと同様にほとんど変化しなかった。




図10 OLSRを利用したセンサネットワークの受信率のホップ数依存性




図11 AODVを利用したセンサネットワークの受信率のホップ数依存性

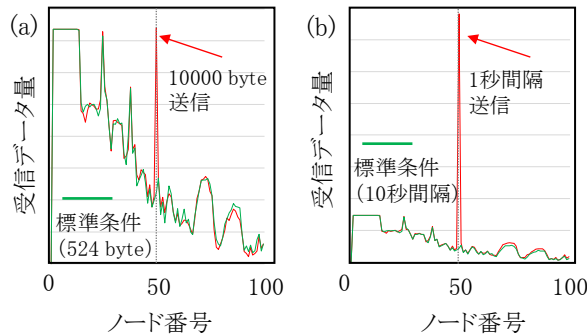


図12 OLSRを利用したセンサネットワークでノード「50」のみ
(a) 1回あたり10000Byte、(b) 1秒間隔、で送信した際の受信データ量

3 まとめ

千葉工業大学内の風力発電設備の支柱に設置したボルトの緩みの有無を、支柱に設置した加速度センサの出力を機械学習で解析することより自動判別可能か検討した。加速度データのLPCケプストラムを入力データとして、SVMによる状態の分類を実施すると、95.1%の精度で、ボルトの緩みの有無を判別できた。さらに、道路沿いに電柱が20m間隔で100本設置された電柱に取り付けられた無線センサノードで構成されるセンサネットワークのシミュレーションを実施した。ルーティングプロトコルのOLSRとAODVを比較した場合、OLSRと比較してAODVの方がホップ数の増加に伴い、急激に受信率が低下し、ホップ数が67を超えると受信率が0%となった。また、ノードの内、1つのノードの送信データの総量を10~20倍増加させた場合、送信1回あたりのデータ量を増加させると受信率が大幅に低下するが、送信間隔を短くすることで疎送信データの総量を増やした場合は、受信率の大幅な低下が見られないことが判明した。

【参考文献】

- [1] 「インフラ維持補修・更新費の中長期展望」平成 30 年 3 月 29 日 内閣府
http://www5.cao.go.jp/keizai-shimon/kProceedings_WMCSA'99_Second_IIEE_Workshop_on_Mobile_Computing_Systems_and_Applications_aigi/minutes/2018/0329/shiryu_03.pdf
- [2] 横田 昭人, “東京ゲートブリッジの維持管理計画について,”
http://www.ktr.mlit.go.jp/ktr_content/content/000080088.pdf
- [3] 品川祐志, 三田 彰, “1 台の加速度センサのみを用いた建築構造物の振動応答推定手法,” 日本建築学会技術報告集 第 19 巻 第 42 号, pp. 461-464, 2013.
- [4] 赤埴淳一, 川島晴美, 瀬下貴加子, 宮川広子, 平松 淳, “機械学習を用いた水道管漏水検知手法の評価,” 電子情報通信学会 総合大会 B-18-21, 2018.
- [5] 李亮, 大久保孝昭, 松本慎也, 宮本文穂, “無線加速度センサを用いた振動計測システムの老朽橋梁への適用と有用性,” コンクリート工学年次論文集, Vol 36, No. 2, pp.1309-1314, 2014.
- [6] F. Itakura, “Line spectrum representation of linear predictor coefficients of speech signals,” The Journal of the Acoustical Society of America 57, S35, 1975.
- [7] 今川直樹, 中垣淳, 宮永喜一, 吉田則信, “ケプストラム分析を用いた線形予測法によるスペクトル推定法,” 電子情報通信学会技術研究報告. CAS, 回路とシステム 100(573), pp. 51-56, 2001.
- [8] L. Breiman, “Bagging Predictors,” Machine Learning, vol. 24, pp.123-140, 1996.
- [9] C.-W. Hsu, C.-J. Lin, “A comparison of methods for multiclass support vector machines,” IEEE Transactions on Neural Networks, Vol. 32, Issue 9, pp. 1627-1645, 2010.
- [10] 国土交通省 電柱本数の推移 http://www.mlit.go.jp/road/road/traffic/chicyuka/chi_13_03.html
- [11] C.E. Perkins, and E.M. Royer, “Ad-hoc on-demand distance vector routing,” Proceedings WMCSA'99. Second IEEE Workshop on Mobile Computing Systems and Applications, pp. 1-10, 1999.
- [12] B. R. Arun Kumar, L. C. Reddy, P. S. Hiremath, “Performance Comparison of Wireless Mobile Ad-Hoc Network Routing Protocols,” International Journal of Computer Science and Network Security, VOL.8 No.6, pp. 337-343, 2008.

〈発 表 資 料〉

題 名	掲載誌・学会名等	発表年月
なし		