AI を利用した FEM 逆解析による劣化調査

FEM 逆解析の応用事例としてカーブミラーなどに使用される
ポールの劣化調査についての解説

㈱田代合金所 CTO　新納　義昭

1. 緒言

ここでは、FEM 逆解析の応用事例について主に記述していくが、最近の AI、とくにディープラーニングを利用した AI を使うことによって FEM 逆解析が可能となった。

これまで一般解として追及されてきたが実現されなかった FEM 逆解析を使ってどのようなことができるのかを現在では考えることができるようになってきている。

FEM 逆解析の応用の一つとしてインフラの劣化を推定できるシステムの構築を目指すことにした。

2. 最近の AI の発展

本題に入る前に前提となる最近の AI、ディープラーニングについて説明する。

歴史的にはコンピュータによる脳機能のシミュレーションとして生物の神経細胞を模してニューロン、ニューラルネットワークが考えられた。

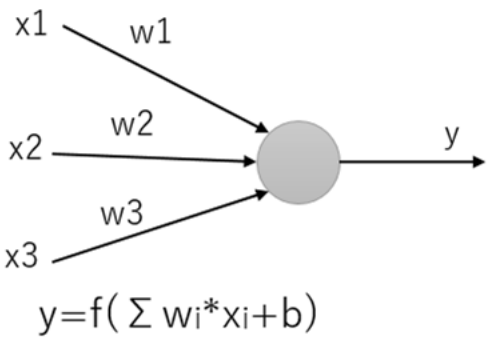

第 1 図

第 1 図のように各入力値に重みをかけ、バイアスを足し算する単純な 1 次方程式の解を集計し、その値を活性化関数で演算した値を出力する仕組みを多数組み合わせたものがニューラルネットワークとなる。ディープラーニングとは、この重みやバイアスのパラメータを学習データ(入力値とその結果の組み合わせ)により学習させることで導き出すことである。パラメータを決めるためには、最適化の手法を使って収束するまで繰り返し何度も計算し学習するので大規模な解析マシンと膨大な時間が必要であるが、いったんパラメータが学習により求まれば、単純な掛け算と足し算の組み合わせにより結果が得られる。つまり実際の調査時には、タブレットやスマホなどの軽量なマシンを用意するだけで結果が得られる。

ニューロン一つで NAND（NotAND）回路を実現でき、NAND 回路の組み合わせは二進数であらゆる演算を表現することができることから、ニューラルネットワークでの学習は、入力値から結果を求めるコンピュータソフトを作成することと同等以上の意味がある。

ニューラルネットワークは、ニューロンを使ったもの以外でも、最近では画像認識のために CNN(ConvolutionalNeuralNetwork、畳み込みニューラルネットワーク)や文章、音など順番に依存する解析のために RNN(RecurrentNeuralNetwork)や LSTM（LongShortTerm）などの手法も考えだされている。

3. AIと構造評価

AI を利用した構造評価のシステムとしては、最近の画像解析技術を利用して構造物の写真解析からクラックや腐食程度などを評価することが行われている。

写真からクラックの進展具合を AI の画像解析技術によって人間の目では判別が難しいものや見落としがちなものを識別し、その構造物がどの程度劣化しているかを判断する方法である。

この方法は、画像を取得するだけで構造物のクラックや腐食による劣化を推定することができるのでこれまで人間が構造物の近くで検査していたのと比べると簡単に結果を得ることができる。さらに技術が進歩すれば、表面の状態から内部の劣化程度も推定することができる可能性もある

反面、多数の学習データを得ることが困難なこと、学習データと検査したい構造物の形状、材料が異なる場合、推定できないか、間違った結果となる危険性があることなどの欠点がある。

4. AIと数値シミュレーション

これらの欠点を克服するために、FEM 解析や流体解析などの数値シミュレーションをディープラーニングの学習データを作成することに使うことで AI を活用した劣化調査を行う方法がある。

数値シミュレーションは条件を変えて大量の学習データを作成することができ、多様な問題に対してより精度の高い結果を得ることができる。

ただ、シミュレーションなので現実を正確にシミュレーションできているとは限らない。たとえば、材料にしてもシミュレーションで使用した材料特性と実際のものとが違っている可能性があるし、設計と施工とが食い違っていることもある。

このような欠点を克服するために、材料特性や施工のばらつきを考慮した学習データを作成し、実物とシミュレーションモデルとの誤差を吸収することでより汎用性の高いものにすることができる。

5. AIを利用したFEM逆解析

第 2 図のように FEM 解析の入力と出力を逆にしてディープラーニングの入出力とすることで FEM 解析の出力、例えば得られた変位から欠陥を解析することができる。入出力が逆になっているので FEM 逆解析と表現している。AI を利用しない逆解析も様々な試みが行われてきたが、解析に合わせて数式モデルを作る必要があるのでできたとしても汎用性の少ないものであった。AI を利用することで、逆解析の汎用性が大きく広がっている。

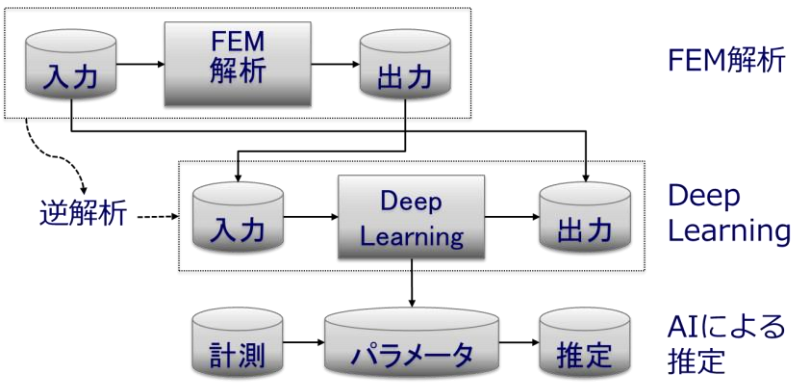

第 2 図

また、AI を利用した FEM 逆解析は図のように三段構造となっていてディープラーニングの学習データを得るための FEM 解析、ディープラーニング、その結果を活用する AI による推定、となっている。いったんディープラーニングにより逆解析のパラメータを求めれば、スマホやタブレット端末の

ような持ち運びできる機器でもほぼリアルタイムに逆解析を行うことができる。

ここで議論する劣化調査における欠陥は FEM 解析に使用するモデルの形状を変えることで表現できるので FEM 解析では入力データとなる。FEM 解析結果である変位をディープラーニングの入力値として使い欠陥を教師データとして使うと変位から欠陥が推定できることになる。

今回は、この AI を利用した FEM 逆解析の手法を使って劣化調査する方法について街、山中を問わずいろいろなところに設置されているカーブミラーのポールを例に説明する(写真 1 参照)。

写真 1

6. FEM 逆解析を利用したミラーポールの劣化調査(引張試験による方法)

(1) 概要

ミラーポール(カーブミラーの支柱)の劣化をその頂部を引っ張ることで調査する方法である。

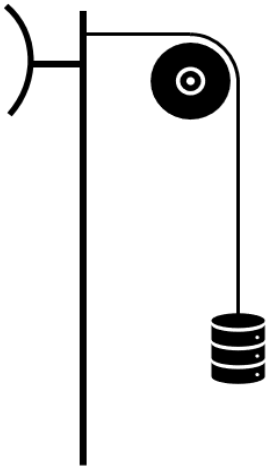

第 3 図

ミラーポールはいたるところに設置されているが、劣化調査をすべてにおいて行うことは数が多いだけにほぼ不可能に近い。劣化が進んで強風や地震などで倒れたり飛ばされたりすると危険なので職員が危険と思われる物件を目視で判断して取り替えているのが現状である。

今回はこのミラーポールを FEM モデル化、FEM 解析し、ディープラーニングにより FEM 逆解析を実施、その変位から劣化程度を推定するパラメータを作成する。

第 3 図のような装置により 20 キロ程度の重りで引張試験を行い、その変位が劣化程度、位置によって変化することから、変位を測定することで劣化の程度を推定する。この方法は外見では問題なく見えても内部で劣化している場合も、調査できるのが先の目視による推定と比べて優位である。もちろん目視による推定と違って検査に

未熟な人でも同じ結果が得られるなどの利点もある。

ミラーポールは、外径が 76.3 ㎜、肉厚が 1.2 ㎜の円筒になっている。長さは 3.6m と 4m のものがあり、下部がカーブしているものとストレートになっているものとがある。今回は長さが 3.6m でストレートのものを例にとって説明する。

設置する場所によってポールが地中に埋まっている長さが異なり、ミラーの取り付け角度、取付位置が変化し、また、変位を測定するために荷重をかける位置、方向もその都度ある程度の誤差で変化するのでそれらを網羅できるようにパラメータを作成することを目標とした。

(2) FEM モデル

FEM モデルは Abaqus で作成した。梁要素で作成し、ミラー部分は集中質量として解析を行った(第 4 図参照)。

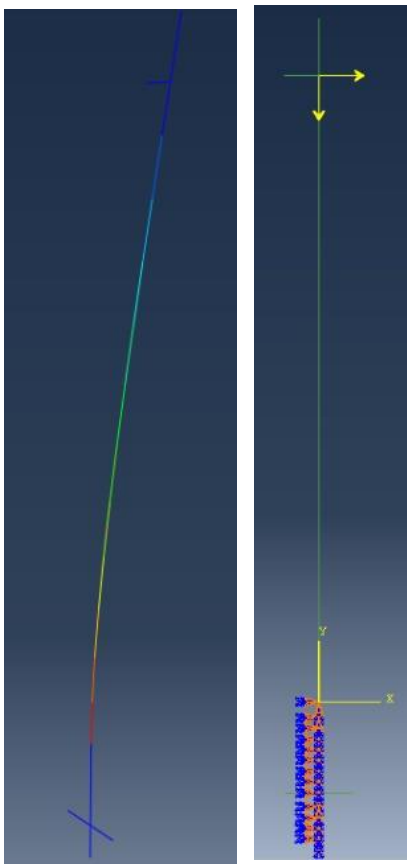

第 4 図

荷重は第 3 図のようにかけるので実際の作業ではロープの角度や荷重点がずれることが予想される。そこで、荷重点をある程度の幅でランダムな位置、方向にしてある程度のずれを許容するために 100 万個のモデルを作成した。

またミラーポールを地中に埋める深さも現場の状況に応じて異なることが予想されるのでランダムな深さで固定するモデルを作成した。

ミラーの重さ、固定位置も同じ考えで作成している。

劣化は、逆解析で推定する対象なのでパイプの減肉量、減肉位置、減肉幅をランダムに変化させて変位量の変化と対応関係データを作成した。

(3) AI(ディープラーニング)モデル

ディープラーニングを行うソフトは Google の Tensorflow をバックエンドとした Keras を使用した。入力としては、Abaqus による FEM 解析結果の変位を使用した。ディープラーニングの出力は、劣化箇所、すなわちパイプの減肉位置と減肉量である。

先に書いたように FEM 解析によって 100 万通りのデータを用意した。そのうち 90 万通りを学習データとし、残り 10 万通りを検証用データとした。

学習は第 5 図の通り進んだ。epoch_categorical_accuracy が正解率、epoch_loss が誤差である。学習は Batch 長さ 3000 のデータを用い、145 回でほぼ正解率 1 に近い値となった。

ディープラーニングモデルとしては、変位量は画像と同じように考えることができるので画

像解析用の 1 次元、2 パラメータの CNN を用い、その出力と全結合のニューラルネットワークとを組み合わせた。変位量は圧縮方向に比べて曲げ方向が大きいのでこのモデルでは(x,z)の 2 方向の変位を入力データとして用いた。梁要素なので 1 次元の画像処理として（N,2）のマトリックスデータを作成した（N は、変位の評価点数)。

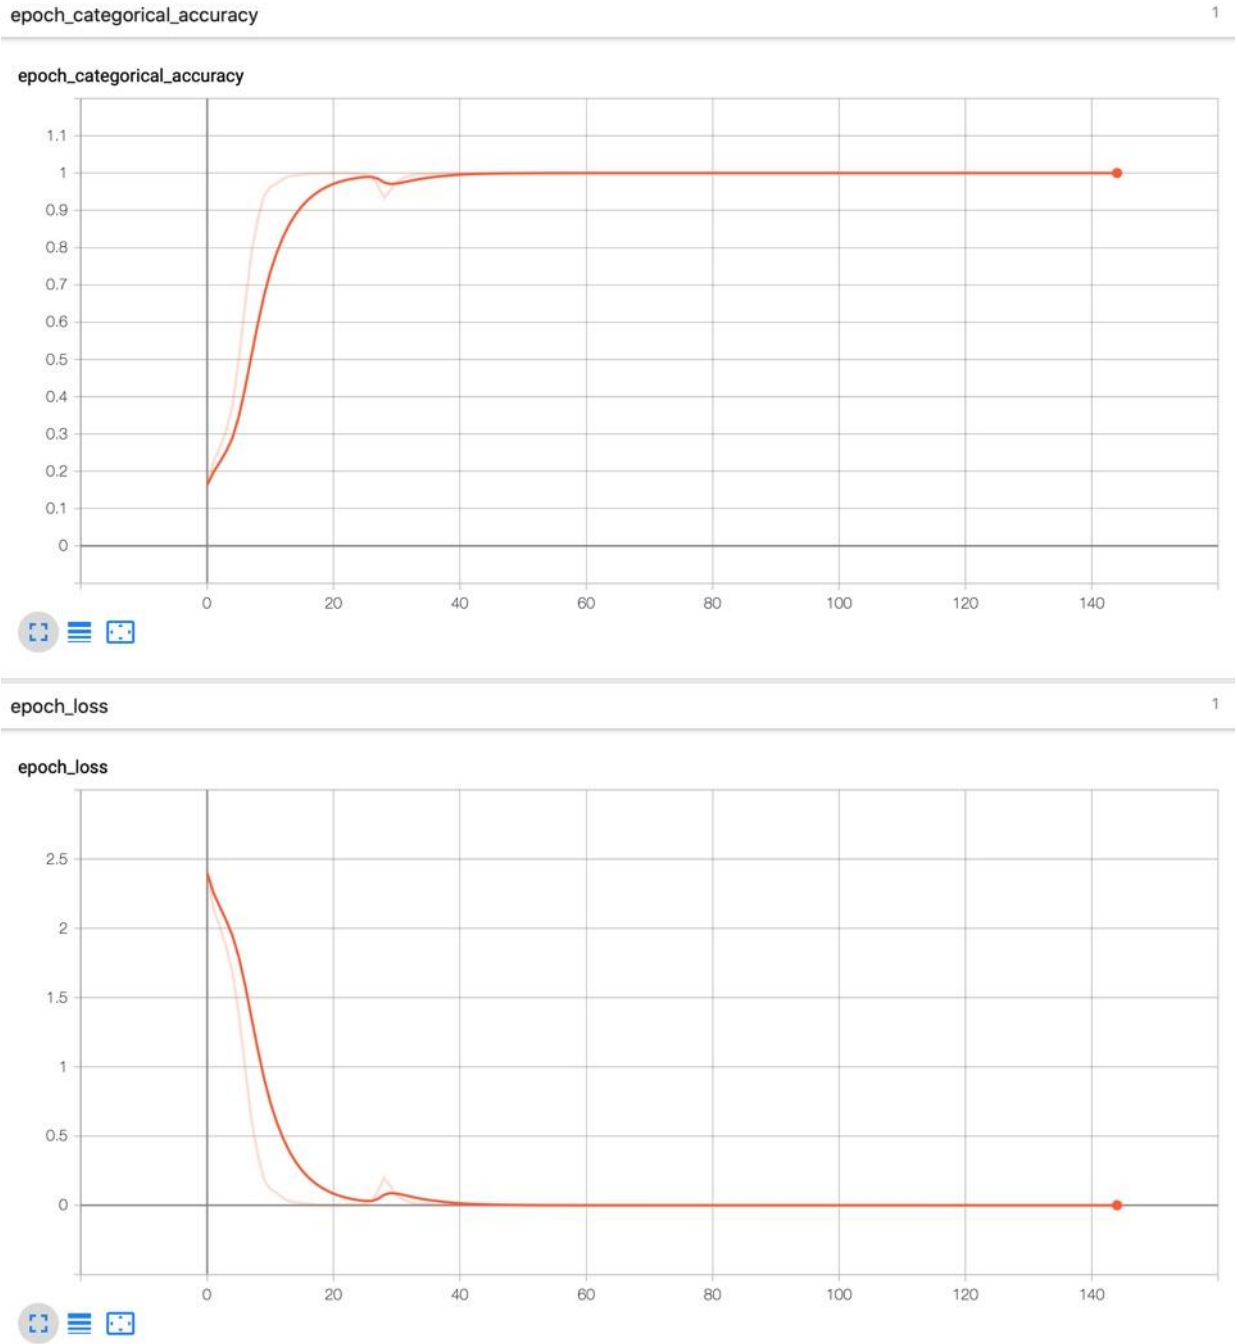

第 5 図

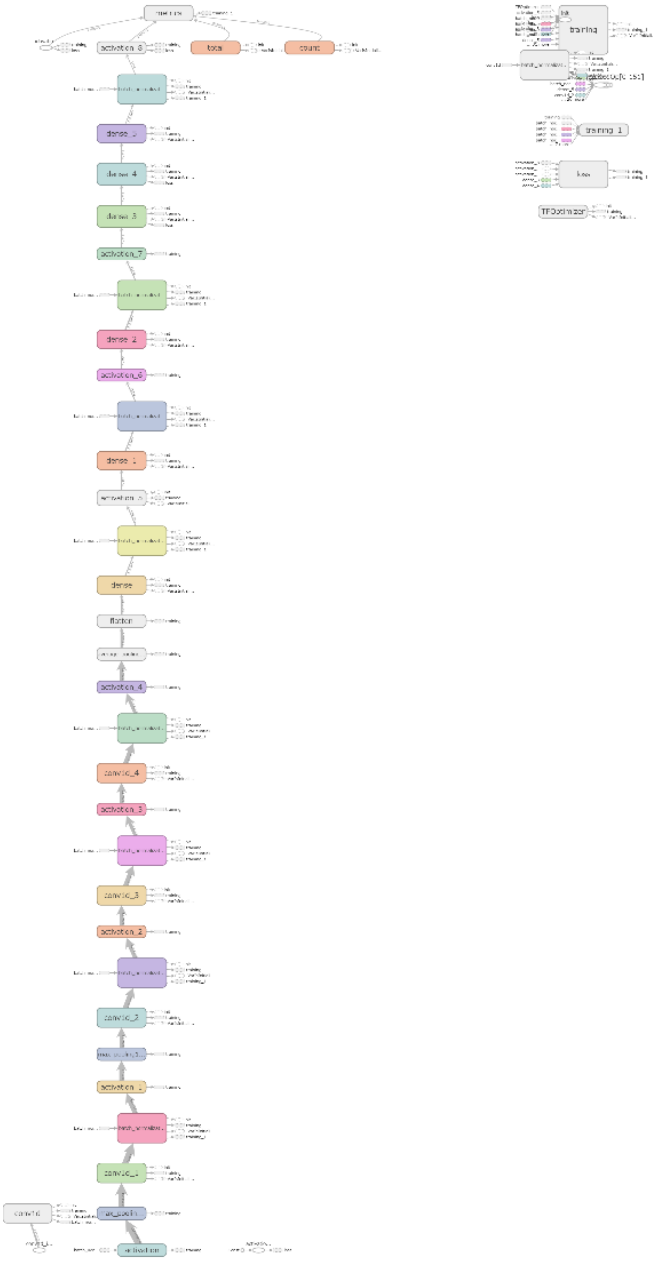

第 6 図

モデルは、第 6 図のように 1 次元の Convolution 層が 6 層、Pooling 層が 2 層、全結合層が 5 層の、入出力層を合わせて合計 13 層のニューラルネットワークとなっている。

劣化状態は、減肉量を 0 から 13 の 14 段階(値の小さい方が劣化程度が少ない)で推定し、減肉位置は地上部分を 200 ㎜ごとに分割した位置を 12 段階で推定した。いずれも出力層は Softmax 関数を用いているので結果は確率で表示される。

(4) 結果

ディープラーニングを行った結果のうち減肉量を第 1 表に、減肉位置を第 2 表に示す。これは AI による逆解析がどの程度、FEM 解析の再現性があるかを示す。

学習に使用したデータとは別の検証データで任意の 30 個分の結果を表にまとめた。表の太字部分は AI が推定した値、塗り部分は推定と違った FEM 解析値である。

減肉量は、30 ケース中、28 ケースで推定は合っている。減肉位置は、30 ケース中、27 ケースであっている。推定が間違っていたものも近い位置にあるか、確率が高いものになっているので推定値または 2 番目の推定値を使えば、実際の値になる。

第１表

CASE	0	1	2	3	4	5	6	7	8	9	10	11	12	13
1	0.0%	0.0%	0.0%	0.1%	0.0%	0.5%	0.0%	0.6%	**97.1%**	0.1%	1.0%	0.7%	0.0%	0.0%
2	0.1%	0.0%	0.1%	1.2%	1.3%	2.6%	4.4%	20.7%	**53.9%**	9.2%	6.4%	0.0%	0.0%	0.0%
3	0.0%	0.0%	0.0%	0.0%	0.0%	0.3%	0.0%	0.0%	0.0%	0.5%	0.0%	0.0%	0.0%	**98.2%**
4	8.2%	**46.1%**	10.0%	2.7%	1.2%	21.5%	6.7%	2.9%	0.5%	0.0%	0.2%	0.0%	0.0%	0.0%
5	7.8%	15.8%	**34.5%**	25.0%	3.5%	1.3%	3.2%	0.0%	5.4%	2.3%	0.0%	0.0%	0.2%	0.0%
6	0.3%	6.0%	7.8%	0.8%	0.3%	0.4%	11.5%	1.6%	8.6%	11.2%	**20.5%**	20.5%	10.5%	0.0%
7	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.1%	**97.2%**	0.7%	1.9%	0.0%	0.0%	0.1%	0.0%
8	0.2%	3.4%	11.5%	2.1%	4.2%	4.2%	0.1%	5.2%	**67.9%**	0.9%	0.5%	0.0%	0.0%	0.0%
9	23.0%	**24.9%**	17.0%	16.7%	11.2%	2.3%	1.3%	2.4%	0.3%	0.0%	0.8%	0.0%	0.0%	0.0%
10	4.4%	1.4%	25.5%	**31.2%**	17.3%	3.9%	2.6%	0.5%	2.5%	0.0%	5.9%	0.0%	4.8%	0.0%
11	0.2%	0.0%	0.0%	0.2%	0.0%	0.0%	1.7%	2.8%	0.0%	1.9%	28.1%	**36.0%**	27.6%	1.5%
12	20.6%	**30.7%**	11.3%	10.3%	7.9%	9.0%	2.1%	6.0%	1.8%	0.3%	0.0%	0.0%	0.0%	0.0%
13	2.7%	**52.9%**	27.2%	7.5%	5.7%	2.0%	1.0%	0.0%	0.2%	0.3%	0.6%	0.0%	0.0%	0.0%
14	3.7%	5.9%	**63.5%**	0.4%	3.4%	0.0%	0.1%	0.1%	22.3%	0.3%	0.0%	0.2%	0.0%	0.0%
15	9.7%	2.4%	15.0%	16.8%	**29.0%**	18.9%	3.8%	4.2%	0.2%	0.1%	0.0%	0.0%	0.0%	0.0%
16	17.8%	**18.8%**	15.9%	15.7%	13.0%	13.0%	3.4%	0.4%	0.3%	0.3%	1.0%	0.0%	0.3%	0.0%
17	0.0%	0.0%	0.1%	1.5%	0.7%	0.0%	0.0%	**79.0%**	0.3%	0.1%	16.8%	0.1%	1.5%	0.0%
18	13.8%	**36.2%**	21.2%	6.3%	7.4%	4.4%	8.2%	1.6%	0.4%	0.2%	0.0%	0.0%	0.1%	0.0%
19	0.0%	0.0%	0.0%	0.0%	0.0%	0.8%	1.5%	0.0%	**95.4%**	1.3%	0.0%	0.0%	0.0%	0.0%
20	0.0%	0.0%	0.0%	**99.1%**	0.0%	0.0%	0.4%	0.0%	0.0%	0.0%	0.4%	0.0%	0.0%	0.0%
21	17.6%	**34.0%**	14.9%	17.1%	2.8%	7.1%	3.6%	0.5%	0.9%	0.1%	1.2%	0.0%	0.1%	0.0%
22	0.0%	0.0%	0.0%	0.1%	0.0%	0.0%	**73.0%**	0.0%	0.0%	0.1%	26.4%	0.4%	0.0%	0.0%
23	0.0%	0.0%	0.0%	0.8%	**98.3%**	0.8%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%
24	0.0%	0.0%	0.0%	0.0%	0.0%	25.4%	0.0%	0.0%	**74.3%**	0.0%	0.2%	0.0%	0.0%	0.0%
25	0.0%	0.0%	0.0%	0.1%	0.0%	0.0%	0.1%	0.4%	**98.3%**	1.1%	0.0%	0.0%	0.0%	0.0%
26	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	6.4%	0.1%	0.8%	4.1%	0.0%	**79.7%**
27	4.4%	**33.3%**	29.3%	19.9%	3.7%	2.3%	3.9%	3.0%	0.0%	0.0%	0.0%	0.1%	0.0%	0.0%
28	17.2%	20.2%	**34.0%**	13.7%	3.0%	6.8%	1.5%	0.6%	2.7%	0.0%	0.1%	0.0%	0.2%	0.0%
29	0.0%	0.0%	0.0%	7.6%	0.0%	**81.3%**	0.0%	0.0%	0.0%	0.0%	0.2%	0.2%	10.4%	0.3%
30	1.1%	2.0%	0.5%	24.2%	1.1%	**65.0%**	2.0%	2.4%	1.4%	0.0%	0.1%	0.0%	0.2%	0.0%

第２表

CASE	～200	200~400	400~600	600~800	800~1000	1000~1200	1200~1400	1400~1600	1600~1800	1800~2000	2000~2200	2200~
1	**62%**	38%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
2	0%	0%	0%	0%	0%	0%	**65%**	35%	0%	0%	0%	0%
3	0%	0%	0%	0%	0%	0%	**100%**	0%	0%	0%	0%	0%
4	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	**100%**
5	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	**100%**
6	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	**100%**	0%
7	0%	0%	0%	0%	0%	0%	**70%**	30%	0%	0%	0%	0%
8	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	**100%**	0%
9	0%	**100%**	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
10	0%	0%	0%	0%	0%	0%	**96%**	4%	0%	0%	0%	0%
11	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	**100%**
12	0%	0%	0%	0%	0%	0%	0%	0%	0%	**100%**	0%	0%
13	0%	**99%**	1%	0%	0%	0%	0%	0%	0%	0%	0%	0%
14	0%	0%	**100%**	0%	0%	0%	0%	0%	0%	0%	0%	0%
15	0%	0%	0%	0%	0%	0%	0%	0%	**100%**	0%	0%	0%
16	0%	0%	0%	7%	**93%**	0%	0%	0%	0%	0%	0%	0%
17	0%	0%	0%	0%	0%	0%	0%	0%	0%	**100%**	0%	0%
18	0%	1%	**67%**	0%	0%	0%	0%	0%	0%	0%	0%	32%
19	0%	**100%**	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
20	0%	0%	0%	0%	0%	**55%**	45%	0%	0%	0%	0%	0%
21	0%	0%	0%	0%	9%	**91%**	0%	0%	0%	0%	0%	0%
22	0%	0%	0%	0%	0%	0%	**90%**	10%	0%	0%	0%	0%
23	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	**100%**
24	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	**100%**
25	0%	0%	0%	0%	7%	**76%**	0%	0%	0%	0%	17%	0%
26	0%	0%	**100%**	0%	0%	0%	0%	0%	0%	0%	0%	0%
27	**100%**	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%
28	0%	0%	0%	0%	0%	0%	**100%**	0%	0%	0%	0%	0%
29	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%	**100%**
30	0%	0%	0%	0%	**100%**	0%	0%	0%	0%	0%	0%	0%

7. FEM 逆解析を利用したミラーポールの劣化調査(打撃音による方法)

(1) 概要

荷重を加えてその変位で劣化を調査する方法は、計測に手間暇がかかる。そこで、ポールをハンマーなどでたたいて音を計測することで劣化箇所を調査する方法を検討する。

この場合も、ハンマーを正確な位置でたたくことができるわけではないので、ある程度のずれを許容できるようにＦＥＭモデルを作成し学習を行った。

(2) FEM モデル

FEM は過渡応答解析を行った。応答解析でもモデルは前項と同じである。

荷重は、ハンマーでたたくことを想定し、0.001 秒後に減衰するように設定した。

荷重点、支持点などは前項の引張試験による方法と同じようにある程度の幅でランダムに与えた。

劣化具合も同様にランダムに変化させて解析した。

過渡応答解析は、モード法で行い、可聴域である 10KH z までの固有値から応答を計算した。

計測点は、地上部分の、ほぼ 100 ミリおきの 23 節点を対象として応答値を計算した。

(3) AI モデル

前項と同じく Tensorflow-Keras を用いてディープラーニングを行った。

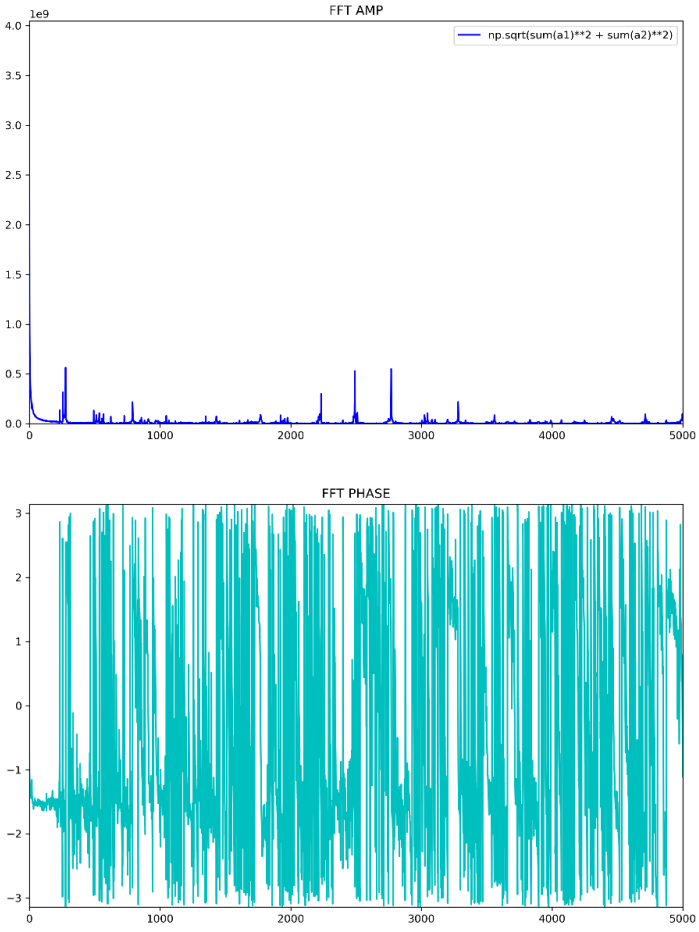

第 7 図

データは 21 万通りを用意し、その 9 割を学習データに、残り 1 割のデータを検証用として用いた。

実際の音の変化で劣化具合を推定することを想定しているので、過渡応答で得られた各計測点の波形を合成してフーリエ変換し、現実の音の波形をフーリエ変換したものと合わせることにした。第 7 図は、5 KH z までをプロットしたもので上が周波数、下が位相である。

そこで AI の入力はその合成波形としその波形から劣化具合、劣化の程度と劣化の位置、を推定することにしている。

AI モデルは、第 8 図のように一次元の畳み込み層を 5 層、プーリング層を 3 層、全結合層を 6 層の合計 14 層で構成した。

学習は Batch 長さ 300 個のデータで 3000 回行っている。正解率は約 6 割、誤差は 1 程度残る結果となった。

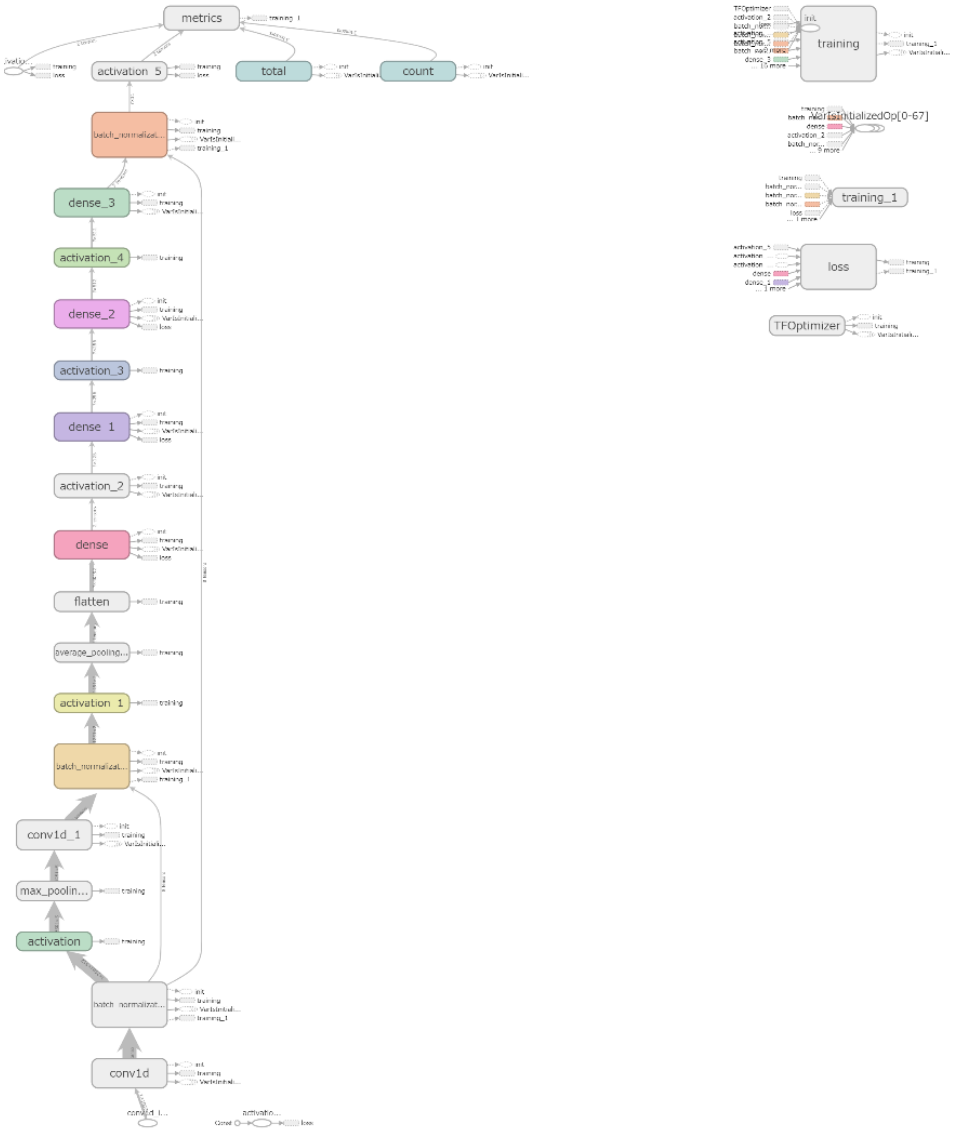

第 8 図

(4)　結果

第 3 表に予測値と FEM 解析した結果との差のうち、減肉量のみを示す。表のように 30 個サンプリングしたもので 25 個が正解であった。前項と同じく不正解ケースはマス塗りで示す。

本方法が実物で有効か否かを確認するために実際にカーブミラーのポールを素手でたたいて得た音から取得した波形を FFT 変換し、上のディープラーニングの結果と合わせた。第 9 図に実物のフーリエ変換したものとそれに近い FEM 解析の図を示す。

結果は、5 本のうち 1 本のポールを除いてすべて異常なしとなった。異常と判断された 1 本のポールは確かに目視した限りでは下部の腐食が激しいように思われた。

(5)　今後の展開予定

今回は間に合わなかったが、九州のある自治体の協力を得て実際に腐食の可能性の高いポールを使って本手法による劣化調査が有効か否かを検証する予定である。

その結果が出たらいずれご報告したい。

8. 結言

最近の AI、主にディープラーニング手法、ハード面では GPU 性能の著しい発展によりこれまで一般解としてはできなかった FEM 逆解析ができるようになってきた。今回はその応用の一つとして簡単

第 3 表

CASE	0	1	2	3	4	5	6	7	8	9	10
1	0%	0%	0%	0%	0%	0%	0%	0%	**100%**	0%	0%
2	0%	**100%**	0%	0%	0%	0%	0%	0%	0%	0%	0%
3	0%	0%	**99%**	0%	0%	0%	1%	0%	0%	0%	0%
4	0%	**99%**	0%	0%	1%	0%	0%	0%	0%	0%	0%
5	0%	0%	0%	0%	0%	0%	**99%**	0%	0%	0%	0%
6	0%	0%	1%	**99%**	0%	0%	0%	0%	0%	0%	0%
7	0%	**100%**	0%	0%	0%	0%	0%	0%	0%	0%	0%
8	0%	8%	0%	0%	0%	0%	**92%**	0%	0%	0%	0%
9	**64%**	35%	0%	0%	0%	0%	0%	0%	0%	0%	0%
10	0%	10%	7%	24%	6%	12%	**41%**	0%	0%	0%	0%
11	0%	0%	0%	12%	0%	0%	0%	**87%**	0%	0%	0%
12	0%	0%	**50%**	0%	0%	0%	50%	0%	0%	0%	0%
13	0%	0%	0%	**61%**	12%	0%	27%	0%	0%	0%	0%
14	0%	0%	0%	0%	0%	0%	0%	0%	0%	**100%**	0%
15	0%	**100%**	0%	0%	0%	0%	0%	0%	0%	0%	0%
16	0%	**100%**	0%	0%	0%	0%	0%	0%	0%	0%	0%
17	0%	**99%**	0%	0%	0%	0%	0%	0%	0%	0%	0%
18	0%	0%	0%	**100%**	0%	0%	0%	0%	0%	0%	0%
19	0%	0%	0%	0%	**98%**	0%	2%	0%	0%	0%	0%
20	0%	0%	**98%**	2%	0%	0%	0%	0%	0%	0%	0%
21	0%	0%	0%	**100%**	0%	0%	0%	0%	0%	0%	0%
22	0%	12%	0%	**88%**	0%	0%	0%	0%	0%	0%	0%
23	0%	**99%**	1%	0%	0%	0%	0%	0%	0%	0%	0%
24	0%	3%	2%	**95%**	0%	0%	0%	0%	0%	0%	0%
25	0%	0%	0%	**99%**	0%	0%	0%	0%	0%	0%	0%
26	0%	0%	0%	0%	0%	0%	**100%**	0%	0%	0%	0%
27	0%	0%	0%	0%	0%	0%	**100%**	0%	0%	0%	0%
28	0%	**81%**	3%	3%	0%	0%	8%	1%	0%	1%	2%
29	0%	0%	0%	0%	0%	0%	0%	0%	0%	**100%**	0%
30	0%	0%	0%	**99%**	0%	0%	1%	0%	0%	0%	0%

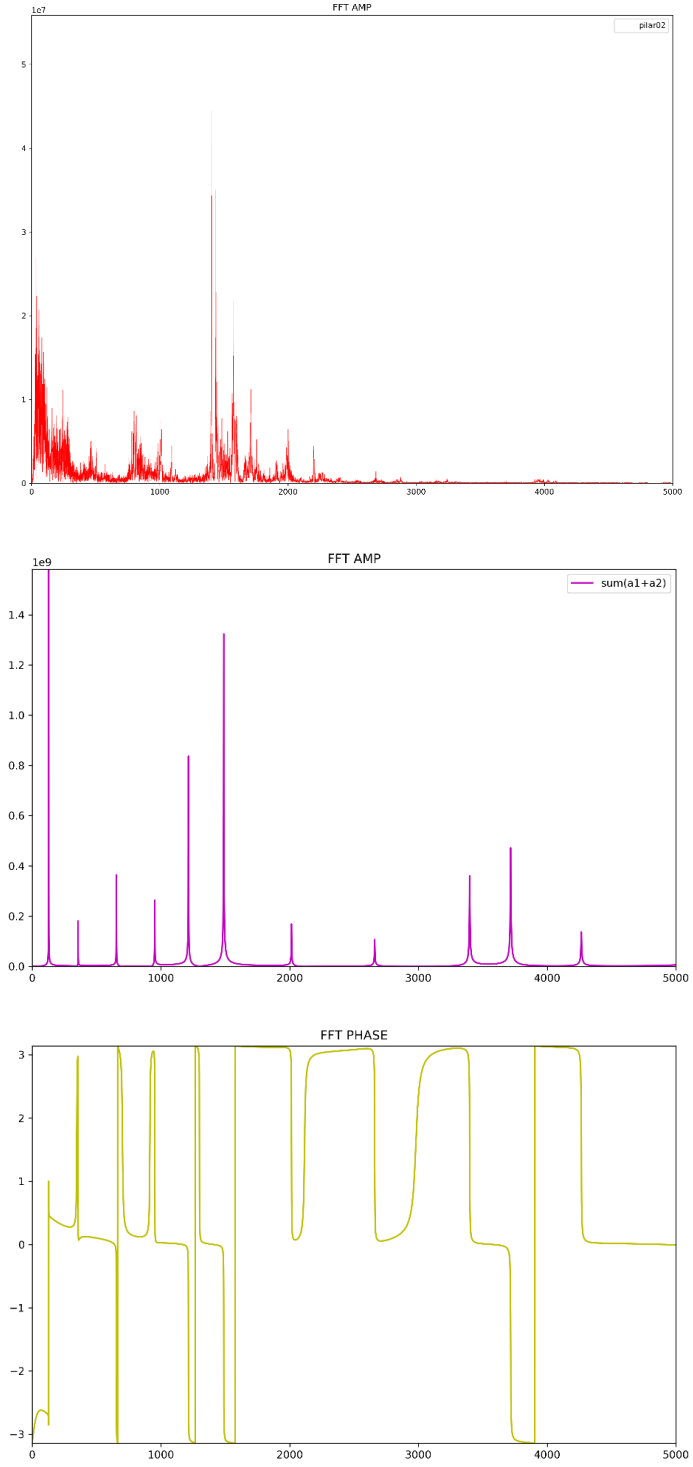

第 9 図

にできる劣化調査を取り上げて解説した。

　取り組みとしては始めたばかりであり、今後の実証が必要であるがその大きな可能性の一端は示すことができたのではないかと思っている。

以上

㈱田代合金所　CTO　新納　義昭

護衛艦や宇宙ステーションの設計･構造解析に長年に渡り従事。

FEM 逆解析や AI を作ったシステム開発にも精通し現在に至る。