深層畳み込みニューラルネットワークによるバルブの健全性診断

野村 泰稔* 井田 一晟** 宮地 翼**
宮本 学** 菅 真人***

Structural Integrity Diagnosis for Valve Based on Deep Convolution Neural Network

by

Yasutoshi NOMURA*, Issei IDA**, Tsubasa MIYAJI**,
Manabu MIYAMOTO*** and Masato SUGA***

Valve is a critical device to control fluid flow as an in-plant installation. However, much accidents due to an out-of-control valve have been reported in the past. One reason that the valve will become out-of-control is a Fixation-damage due to corrosion. It is important to evaluate the structural integrity of valve installed in plants because a fixation-damage causes serious accidents. For the purpose of developing a structural integrity monitoring system of valve, this study attempts to classify structural integrity of valve from vibration image data by using deep convolution neural network. First attempt is made to investigate the relationship between vibration characteristics of the valve with fixed-damage due to corrosion and torque to open/close the valve. Second attempt is made to make training data sets from the torque and the image data of vibration frequency of valve and train deep convolution neural network. Finally, it is demonstrated whether the structural integrity of the valve can be classified by using the trained deep convolution neural network.

Key words:

Deep convolution neural network, valve, Structural health monitoring

1 緒 言

バルブは各種プラント系のプロセスの信頼性を確保する上で、重要な役割を果たしているが、バルブは長期間、開状態あるいは閉状態のまま使用すると、錆びつき固着が発生し、開閉の制御が不能になることが損傷事例として報告されている。動作不良に陥った場合、人命に関わる重大事故を引き起こす恐れがあることから、バルブの健全性を的確に評価することは極めて重要である。現状では、その健全性は主として専門の技術者による定期点検が行われているが、プロセス停止を前提としたオフライン状態で検査されることから効率が悪く、さらに定期点検の間隔が適切でない場合、安定稼動を維持することが困難となる。

このようなことから、バルブの健全性を自己診断するシステムの開発もわずかであるが行われている¹⁾。ただし、これまでに提案されている方法は、錆びつき固着の程度を定量的に評価できることが示されているものの、使用されるバルブ個々にそのバルブの開度とコントローラの出力の力学関係を記述する解析モデルを事前に構築しておく必要があり、さらに、常時、バルブの開度と流量を計測している必要があることから、緊急時のみに作動させる緊急遮断弁やスプリンクラーなどには適用できない。

以上のことから、本研究では、コントローラを作動させることなく、流体の圧力変動に伴うバルブ本体の振動から、錆びつき固着の発生を検知できるシステムの開発を試みる。これまでに、バルブ内部の弁棒が腐食により固着し、その固着程度が進展すると、打撃試験から得られるバルブの振動特性が変化することを確認した²⁾。ただし、常時微動から得られるバルブの振動特性は、打撃試験結果と比較して明確なピークの変化は認められず、定量的・定性的に固着程度を評価することが困難であることが分かった²⁾。そこで本研究では、近年の飛躍的な画像認識精度の向上を遂げた深層学習に着目し、バルブの健全性診断技術の開発を目的として、バルブの流体が流れている際の振動から、周波数特性のフーリエ振幅値と位相を画像化し、深層畳み込みニューラルネットワーク³⁾⁻⁵⁾を用いてバルブの状態を識別することを試みる。

以下では、まず、深層学習の一種である畳み込みニューラルネットワークについて説明する。次に、バルブの固着損傷を再現し、流水試験時の振動計測を行った結果についてまとめる。最後に、流水試験時のバルブの周波数特性を画像化し、深層畳み込みニューラルネットワークCIFAR-10⁶⁾を利用して、健全・軽度の固着・重度の固着のクラス分類を試み、状態識別精度を明らかにする。

† 原稿受理 平成29年7月9日 Received July, 9, 2017 ©2018 The Society of Materials Science, Japan

* 正 会 員 立命館大学 理工学部都市システム工学科 〒525-8577 草津市野路東
College of Science and Engineering, Ritsumeikan Univ., Noji-higashi, Kusatsu 525-8577.

** 立命館大学 理工学部都市システム工学科(井田 現:神戸市役所, 宮地 現:岐阜県庁) 〒525-8577 草津市野路東
College of Science and Engineering, Ritsumeikan Univ., Noji-higashi, Kusatsu 525-8577.

*** ババルブ(株) 〒578-0976 東大阪市西鴻池町
Tomoe Valve Co., Ltd., Nishi-Kohnnoike-cho, Higashi-Osaka 578-0976.

2 畳み込みニューラルネットワーク (CNN)

2.1 畳み込みニューラルネットワークの概要

通常, サポートベクターマシンなどの従来の機械学習技術を用いて, 画像認識を行う場合, 事前の特徴抽出が必須である. 一方, 深層学習では, 画像内のピクセルから線, 線からパーツ, パーツから全体の概念というように階層的に特徴が自動的に抽出されるため, ユーザーが自分で特徴抽出・選択を行うことなく, 自動で概念を高度に学習することができると言われている. 深層学習とは, 多層のニューラルネットワークを用いて機械学習を行う技術の総称であり, 中でも畳み込みニューラルネットワーク (以下, CNN と称す) は, 画像認識分野の中心に最も利用されている深層学習の一つである. CNN は Fig.1 に示すように, 入力層 (Input layer), 畳み込み層 (Convolution layer), プーリング層 (Pooling layer), 全結合層 (Fully connected layer), 出力層 (Output layer) から構成され, 畳み込み層とプーリング層は複数回繰り返して深い層を形成し, その後, 全結合層に続く構成となる. この畳み込み層とプーリング層の繰り返しによるアーキテクチャのルーツは福島らにより提案された Neocognitron⁷⁾ という階層型神経回路モデルにあり, その後, LeCun らによって, 誤差逆伝播法による学習法⁸⁾ が整備されて以来, CNN の基本技術が確立された. 以下に各層の役割について簡単に説明する.

畳み込み層の役割は, 画像の局所的な特徴を抽出することである. 1 層目の畳み込み層では, 入力画像に対して畳み込み処理を行い, 特徴マップを得る. この畳み込みをする際のフィルタは画像内のすべての場所で共有されることから, 単純な全結合型の多層ニューラルネットワークと比較して, 大きくパラメータが削減される. そして2層目以降の畳み込み層では前層の特徴マップを入力として同様に畳み込み処理を行う. ここで画像サイズを $W \times W$ とし, 画像インデックス (i, j) , $(i=0, \dots, W-1, j=0, \dots, W-1)$ で表すとする. 画素 (i, j) の画素値を x_{ij} と書き, 負の値を含む実数を取るとする. そして, 小さいサイズ $H \times H$ 画素のフィルタの画素のインデックス (p, q) , $(p=0, \dots, H-1, q=0, \dots, H-1)$ で表し, その画素値を h_{pq} とすると, 画像の畳み込み処理は以下のように計算される.

$$u_{ij} = \sum_{p=0}^{H-1} \sum_{q=0}^{H-1} x_{i+p, j+q} h_{pq} \quad (1)$$

なお, フィルタを畳み込む間隔は任意で決定できる. そして, 畳み込んで得られた値を, シグモイド関数や $\tanh$ 関数, ReLU (正規化線形関数) などの活性化関数に与えて, その出力を特徴マップの値とし, 次層に引き継ぐ.

プーリング層は, 畳み込み層から出力された特徴マップをまとめ上げ, 縮小する役割を担う. このとき着目する領域を指定し, その着目領域の特徴マップの値から新たな特徴マップの値を求める. 着目領域を例えば 3×3 画素とすると, その9個の画素値から, 最大値を選ぶ最大値プーリングや, 平均値を選ぶ平均プーリングなどがある. プーリング層を交えることで, 位置変更への感度を下げ, 小さな平行移動に対する普遍性を持たせる役割を果たすことが分かっている.

全結合層では, 多層ニューラルネットワークと同様に重み付き結合を計算し, 活性化関数によりユニットの値を求める. 全結合層の入力は畳み込み層またはプーリング層であり, これらの層は2次元の特徴マップであることから, 全結合層に入力するために1次元情報に展開する.

出力層では, 多層ニューラルネットワークと同様に, 尤度関数を用いて, 各クラスの尤度を算出する.

今, 出力層 $l=L$ の各ユニット $k(=1, \dots, K)$ のすべての入力は, 1つ前の層 $l=L-1$ の出力を元に $u_k^{(L)}$ と与えられたとする. これを元に, 出力層の k 番目のユニットの出力を, 以下のソフトマックス関数を用いて計算する.

$$y^k \equiv z_k^{(L)} = \frac{\exp(u_k^{(L)})}{\sum_{j=1}^K \exp(u_j^{(L)})} \quad (2)$$

こうして算出される出力 $y^1, \dots, y^K$ は, 総和がいつも1になるように正規化する. 今考えているクラスを $C_1, \dots, C_K$ と表すとき, 出力層ユニット k の出力 $y_k (=z_k^{(L)})$ は与えられた入力画像 x が, クラス C_k に属する確率(式(3))を表すものとして解釈する.

$$p(C_k | x) = y^k \equiv z_k^{(L)} \quad (3)$$

そして, この確率が最大になるクラスに入力画像 x は分類される.

Fig.1 Example of Convolution NN.

Fig.2 Network architecture of CIFAR-10.

2.2 CIFAR-10

近年、深層学習のあらゆる可能性が注目されはじめたのは、2012 年開催の画像認識のコンペティション (ILSVRC) で Krizhevsky らの多層ニューラルネットワークが他の手法を圧倒して優勝したことがきっかけである。本研究では Krizhevsky らが作成した airplane, automobile, bird, cat, deer, dog, frog, horse, ship, truck の 10 クラスに分類された、 32×32 pixel のカラー画像をクラスごとに 5,000 枚ずつの学習画像と 1,000 枚のテスト画像ずつの合計 6 万枚で構成されている CIFAR-10⁶⁾ と呼ばれる画像データセットを学習する際に使用するネットワークを利用する。

使用するネットワークを Fig.2 に示す。なお、本研究では収束速度と学習精度の向上を図るために活性化関数の前層にバッチ正規化を行う層を追加している。

3 バルブの固着促進と振動計測

3.1 腐食促進方法

Fig.3 に診断対象のバタフライバルブを示す。バタフライバルブとは、弁棒を 90° 回転させることで、円盤状の弁体が 90° 回転し液体や気体などの流体の方向・圧力・流量を制御する流体制御機器である。本研究では、代表的な腐食促進試験の一つである複合サイクル試験⁹⁾を実施することにより固着を再現した。複合サイクル試験を行ったバタフライバルブの弁棒を Fig.4 に示す。バタフライバルブの弁棒には黒錆および腐食物が付着していることが確認された。実際に稼働中の装置配管で使用され、固着が発生したバタフライバルブの弁棒を Fig.5 に示す。図から明らかなように、実際の配管現場で固着が発生したバタフライバルブの弁棒にも黒錆が発生し、さらに腐食物が付着していることが確認できる。ただし、これらの腐食は、Fig.6 のように、バルブの内部に発生するため、目視で確認できない。腐食により固着が進行する場合、操作トルク量が増加傾向を示すと考えられる。そこで本研究では、腐食による固着進行の判断指標として、バルブ開閉時の操作トルク量を計測することとした。

複合サイクル試験を継続して行った対象のバタフライバルブの操作トルク量を Table 1 と Fig.7 に示す。表内の文字 W は Week を意味し、複合サイクル試験の開始時を W0 として、例えば、W16 は複合サイクル試験開始後 16 週目を意味する。複合サイクル試験を行った 6 台のバルブの平均操作トルクは約 4 ヶ月間で $92.5[\text{Nm}]$ まで段階的に上昇したことから、複合サイクル試験により、固着は徐々に進行したと判断した。なお、W0 の健全時のバタフライバルブの操作トルクはほぼすべてのバタフライバルブでトルクレンチの測定可能トルク以下であった。

Fig. 3 Observation valve.

Fig. 4 Valve stem after a combined cycle test.

Fig.5 Valve stem which caused the fixation in the field.

Fig. 6 Internal condition of damaged valve.

3.2 振動計測方法

本研究では、複合サイクル試験および操作トルクを計測するとともに、Fig.8 に示すように、配管内にバルブを設置し、流水試験を行い、バルブの振動を 3 軸加速度計によりサンプリング周波数 $25.6[\text{kHz}]$ で、5 秒間の計測を 5 回あるいは 10 回行った。Fig.9 に固着の進んでいない健全バルブ (W0) と 16 週間複合サイクル試験を行ったバルブ (W16) の流水試験を行った際の周波数応答の結果を示している。卓越周波数の違いが認められるが、構

Table 1 Time history of torque [Nm].

	W0	W2	W3	W4	W5	W6	W7	W8	W9	W10	W11	W12	W13	W14	W15	W16
Valve1	0.0	1.6	5.1	17.2	24.2	47.0	48.7	58.9	60.3	62.4	69.7	71.1	83.7	85.2	90.5	87.0
Valve2	1.1	2.6	7.7	22.8	21.0	37.4	35.4	48.6	57.3	56.1	58.0	78.0	75.4	85.8	89.7	98.0
Valve3	0.0	1.2	1.2	18.7	28.3	35.7	37.6	43.3	46.9	54.1	48.8	62.3	74.0	77.9	82.4	85.5
Valve4	0.0	1.4	9.9	19.9	42.0	48.9	48.0	51.7	53.3	64.8	66.9	75.0	76.9	79.7	80.5	94.1
Valve5	0.0	4.7	10.9	19.2	37.5	48.5	48.7	54.1	54.5	66.0	70.3	81.5	83.1	81.3	87.5	97.0
Valve6	0.0	1.2	2.1	7.4	15.3	22.1	27.2	33.6	44.5	49.3	58.0	64.3	73.4	77.6	82.0	93.7
Mean	0.2	2.1	6.1	17.5	28.1	40.0	40.9	48.4	52.8	58.8	62.0	72.0	77.7	81.2	85.4	92.5

Fig.7 Results of torque in each valve.

Fig.9 Comparison of FFT results observed under fluid flow tests.

Fig.8 Fluidity test.

造体の振動数であるのか、外力としての流体の振動数であるかを判断ための明確な指標はなく、これらの卓越周波数の違いから固着の有無の判断はきわめて難しいことが分かる。

4 CNN を用いた固着診断

4.1 学習データの生成

本研究では、CNN に流水試験時に計測される対象バルブの周波数応答と操作トルク量から推定するバルブの構造状態（健全・軽度の固着・重度の固着）の組み合わせを学習させた。本研究のように、振動データを扱い、

Fig.10 Examples of Image for the Learning.

Fig. 11 Accuracy for the learning.

教師あり学習を行う場合、振動データから卓越周波数等、何らかの特徴量を抽出し、それを SVM や階層型 NN 等の識別器を用いて学習することが一つのアプローチとして考えられる。ただし、上述したように、外力としての流体の振動数も含むバルブの常時微動データから、構造状態に関する特徴量を抽出することは極めて難しいと考え、自動で識別に必要な特徴を捉えられるとされる深層学習を利用することとした。また、全結合型のニューラルネットワーク（通常の階層型ニューラルネットワーク等）を深層化し、振動データの系列そのものを学習することも一つのアプローチとして考えられるが、学習時の最適化すべきパラメータ（重み係数およびバイアス）の数が、画像を学習する CNN と比較して膨大となることから、本研究では、近年の画像認識精度の大幅な向上を遂げた CNN に期待して、振動データを画像化し、それを学習することを考えた。

まず、流水試験時に計測される 3 軸分の振動データに FFT 処理を施し、卓越する周波数帯を含む領域のフーリエ振幅値と位相を画像化する。具体的には、6 種類のバルブに対して、25.6kHz のサンプリング周期で 5 秒間（128,000 ポイント）の振動計測を 5 回あるいは 10 回ずつ行っている。そして、5 秒間の振動データ 1 つに対して、1024 ポイントずつ FFT 処理を行い、データポイントを重複させず移動窓法を適用し、128,000/1,024 の計 125 枚の 256×256 pixel のサイズの周波数応答画像を生成す

る。例えば、Valve1 において、W0（腐食促進試験開始時）では、振動計測を 5 回行ったことから、それぞれの結果に対して、125 画像生成するので、計 625 枚の画像が生成されることになる。そして、これらの画像に対して、流水試験後に計測された操作トルク量から健全・軽度の固着・重度の固着のクラス符号を紐付けさせる。クラス分けする際のトルク量は 0.0 [Nm] から 25.0[Nm]までを健全状態（符号：0）とし、25.1[Nm]から 50.0[Nm]までを軽度の固着状態（符号：1）、50.1[Nm]以上を重度の固着状態とした。なお、学習データの作成には Valve2 以外の計測データを使用した。Valve2 のデータは未学習データとして、CNN の評価用のデータに用いた。なお、Valve2 は、Fig.7 に見られるように、トルク量の時間的な変化の傾向が、若干、上下に揺れていることから、識別が困難であると判断し、この Valve2 のデータに対して、CNN がどのように状態を識別するか検討した。Fig.10 に学習データの一例を示す。青の線がフーリエ振幅値を、赤の線が位相を表している。軸に数値が残っているが、これらはすべての画像に共通していることから識別に影響を与えないと考え、そのまま残している。学習時に利用した画像は健全状態：21,250 枚、軽度の固着状態：22,500 枚、重度の固着状態：50,000 枚である。

4.2 学習時の精度と未学習データに対する評価

CNN を用いて上記のデータに対して学習を行う際、3,000 枚学習することにより、学習時に用いている画像に対し 30 枚ずつ状態識別した。その結果を Fig.11 に示す。縦軸は識別精度（accuracy、正解の枚数 / 評価総数）と学習誤差（loss）を表しており、横軸は学習の繰り返し回数を示している。図から明らかなように、500,000 回以降で、識別精度が 100%となっていることから、学習データに矛盾するようなデータが含まれず、適切な学習が行われたと判断した。

次に、この学習を行った CNN を用いて、未学習データである Valve2 に対して状態を評価した。Table 2 にその識別結果を示す。表の output の行に関して、In は Intact で健全状態を表し、D は Damage で軽度の固着状態、SD は Severe Damage で重度の固着状態を表している。True の行は、操作トルク量で換算した真のバルブの状態を表している。評価用画像は学習データと同じ条件で生

Table 2 Classification results for the test data (Valve 2)

	W0	W2	W3	W4	W5	W6	W7	W8	W9	W10	W11	W12	W13	W14	W15	W16
In	619	555	1136	1247	943	345	4	118	0	2	1	1	0	3	0	9
D	0	2	11	0	177	269	1189	458	618	174	1	0	1	0	0	5
SD	6	68	103	3	130	636	57	674	632	1074	1248	1249	1249	1247	1250	1236
Output	In	In	In	In	In	SD	D	SD	SD	SD	SD	SD	SD	SD	SD	SD
True	In	In	In	In	In	D	D	D	SD	SD	SD	SD	SD	SD	SD	SD
Torque	1.1	2.6	7.7	22.8	21.0	37.4	35.4	48.6	57.3	56.1	58.0	78.0	75.4	85.8	89.7	98.0

成し, 生成された 625 枚あるいは 1,250 枚の画像に対し, 最も多い評価結果を最終的な推定クラスとした. 例えば, W5 の評価は健全状態が 943 枚, 軽度の固着状態が 177 枚, 重度の固着状態が 130 枚であるので, W5 におけるバルブの状態は健全状態と推定される.

Table 2 から明らかなように, 推定クラスでは 16 週のうち, 14 週で正解の識別をしており, 健全状態, 重度の固着状態の週ではすべて正解している. このことより, 健全状態, 重度の固着状態では, 学習時に使用したデータの周波数特性と同様の周波数特性を呈していたものと考えられる.

一方, W6, W8 は本来, 軽度の固着であるところをどちらも重度の固着であると識別している. 誤った識別をした W6, W8 の内訳を見てみると, 健全状態である W0~W4 や, 重度の固着状態である W10 以降の結果と比べ, システムが識別した結果にばらつきが見られる. W6 は操作トルク量が 37.4[Nm]という軽度の固着の領域 (25.1~50[Nm]) の中央付近の値であるにも関わらず過大評価をしている. この理由を物理的に解釈することは難しいが, トルクを大幅に変えないものの, 振動特性を変化させる錆びつきが生じたと考えられる.

W8 に関しては, 操作トルク量が 48.6[Nm]という軽度の固着の領域の中でも, 重度の固着の領域に近いトルク量であるため, 過大評価の識別をしたものと考えられる. 一方で, 正しい識別であった W5 や W9 に関しても, 誤った出力が多いことから, 健全・軽度の固着・重度の固着の境界領域の識別は難易度が高いと推測できる. この境界領域は, 固着程度を操作トルク量の閾値処理にて, クリスポに設定しただけのものであり, ある意味, 検査者が悩んで設定せざるを得ない領域である. このような領域を教師データとして, 深層畳み込みニューラルネットワークに学習させることから, システムの出力がばらついてしまうと考えられる.

以上の結果をまとめると, 例えば, 検査者が容易に状態を判断できるトルク量範囲 (例えば, 検査者が設定した閾値を大幅に下回るあるいは上回る状況, 健全状態: W0~W4 や重度の固着状態: W10 以降) では, 深層学習も高確率で正答し, 検査者が悩んで設定したトルク量の閾値周辺 (健全状態と軽度の固着状態の境界, 軽度・重度の固着状態の境界) では, システムの出力結果が, 大きくばらつく傾向にある (そのような教師データが与え

られる以上, 避けられない). このことを前向きに解釈すると, 現在, バルブの点検は, プロセス停止を前提とした検査者による定期点検が主流であるが, 点検時に取得した振動データ (フーリエ振幅値と位相) の画像データ群をシステムに入力し, 結果が大きくばらつく際にのみ, プロセスを停止し, 詳細点検を実施するというフローにすることで, 全数検査からの絞り込みが可能になり, 点検業務の省力化が図れると考えられる. ただし, このことは, 各状態の教師データを正確に与えることが前提であるということとは言うまでもない.

5 結 言

本研究では, バルブの健全性モニタリング技術の開発を目的として, バルブを開閉することなく, 流体により常時発生する振動から, 周波数特性のフーリエ振幅値と位相の情報を画像化し, 深層学習の一種である畳み込みニューラルネットワークを用いてバルブの状態を識別することを試みた. 16 週のデータの内, 14 週のバルブの状態を正確に推定することに成功し, 提案手法の有用性が示された. 以下に, 本研究を通じて得られた知見をまとめ, 今後の課題を追記する.

- ・ 周波数特性を表した画像に対して, CNN は適切に学習できることが分かった.
- ・ 学習された CNN を用いて未学習データに対して識別を行った結果, 各クラス間の境界領域では, 誤った識別が多くなるものの, 健全状態, 重度の固着に関しては高い識別精度が得られ, システムの有用性が示された.

今後の最優先の課題は, 正答率を改善することである. 深層学習だけの問題ではないが, 畳み込みニューラルネットワークや各種パターン識別器に学習させる際, 学習データが不足する場合は, 評価時の識別精度を確保することが困難である. 各状態クラス間の境界領域を誤った理由もその一つである. 今後はより多くのデータを収集するとともに, 振動データからどのような情報を画像化するか等, 教師データに与えるべきものを選定していく必要がある. また, 現在までに, 汎化性能を向上させる工夫, 例えば, 複数の状態識別器を構築し, 結果を統合するアンサンブル学習などが提案されていることから, 今後, 検討していく予定である.

また, これらと同時に, バルブの固着診断に関して,

1 期前検査時のデータと現時点での検査データを勘案した教師データを作成し、固着程度とその1期前検査時からの進行度を評価するようなネットワークを構築する予定である。

参 考 文 献

- 1) H. Maruta, M. Kano, H. Kugemoto and K. Shimizu, “Modeling and detection of stiction in pneumatic control valve”, Journal of the society of Instrument and Control engineers (SICE), Vol.40, No.8, pp.825-833 (2004).
- 2) Y. Nomura, I. Ida, T. Miyagi, M. Miyamoto, M. Suga, “Structural integrity monitoring based on deep learning for fixation-damage valve”, Journal of JSCE F6, Vol.72, No.2, pp.I_183-I_190 (2016).
- 3) T. Kamishima, H. Asoh, M. Yasuda, S. Maeda, D. Okanohara, T. Okatani, Y. Kubo, D. Bollegala, “Deep learning”, Kindaikagakusha, (2016).
- 4) T. Okatani, “Deep learning”, Kodansha, (2015).
- 5) T. Yamashita, “An illustrated guide to deep learning”, Kodansha, (2016).
- 6) A. Krizhevsky, “The CIFAR-10 dataset”, CIFAR-10 and CIFAR-100 datasets. [https://www . cs . toronto . edu/~kriz/cifar. html](https://www.cs.toronto.edu/~kriz/cifar.html) (2016/10/20 Accessed)
- 7) K. Fukushima and S. Miyake, “Neocognitron: A new algorithm for pattern recognition tolerant of deformations and shifts in position”, Pattern Recognition, Vol.15, pp.455-469 (1982).
- 8) Y. LeCun, L. Bottou, Y. Bengio and P. Haffner, “Gradient-based learning applied to document recognition”, Proceeding of *IEEE*, pp. 2278-2324 (1998).
- 9) JIS8502, “Methods of corrosion resistance test for metallic coatings”, (1999).