

# 舗装の損傷メカニズムと路面状態の関係に関する研究

研究予算：運営費交付金

研究期間：平30～令2

担当チーム：舗装チーム

研究担当者：藪 雅行、渡邊 一弘、岩永 真和、川上 篤史、前川 亮太、永塚 竜也

## 【要旨】

平成28年に策定された舗装点検要領では、道路の路盤層以下の構造的健全性が重視されている。このことを背景として、路面の点検において構造的損傷との関係を考慮した点検手法の構築が望まれている。そこで本研究では、路面の損傷形状に関する情報と機械学習を組み合わせることにより、新たな構造的健全性の推定手法を構築した。機械学習手法として、画像認識分野にて実用化が進められている深層学習を用いた畳み込みニューラルネットワークを用いることとした。ひび割れ形状としてひび割れ図、わだち掘れ形状として横断プロフィール、アスファルト混合物層の厚さを用いて、構造的健全性の指標であるFWDたわみ量 $D_0$ を推定した。その結果、従来管理指標であるひび割れ率、わだち掘れ量を用いた手法よりも、本手法は誤差の少ない良好な $D_0$ 推定精度が得られた。キーワード：舗装の損傷、路面画像、FWDたわみ量、畳み込みニューラルネットワーク

## 1. はじめに

道路ストックの増加と老朽化の進展を背景として平成28年に舗装点検要領が策定され、要領に基づく点検が進められている。舗装点検要領で示されている管理の指標には、路面性状に関する3指標、ひび割れ率、わだち掘れ量、IRIが挙げられている<sup>1)</sup>。加えて、舗装点検要領では路盤層以下の構造的健全性が重視されており、関連する調査法として非破壊調査のひとつであるFWD (Falling Weight Deflectometer) 調査が広く用いられている。前述した路面性状に関する3指標の算定に必要な路面の状態については、路面性状測定車を用いることにより通行規制を伴わずに把握することが可能である。そこで本研究では、次に述べる2つの着眼点から、構造的健全性について交通規制を要さずに容易に把握するという課題解決が達成し得るのではないかと考えた。

1) ひび割れ率やわだち掘れ量といった管理指標は、実際の路面に生じている現象のごく一部を数値化したものである。ひび割れやわだち掘れの形状をはじめ、発生位置やひび割れ幅のように、既存の管理指標では包含できない情報を活用することにより、路面性状から構造的健全性が推測できないかという点。

2) 近年の、人工知能 (Artificial Intelligence 以下、AI) をはじめとする機械学習の発展により、舗装の維持管理においても、機械学習を用いた技術が開発、実用化されてきている。このような背景から、路面の情報と構造的健全性の関係についても多面的に推測すること

ができないかという点。

本研究では、ひび割れ図や横断プロフィールといった画像として出力されるひび割れ形状やわだち掘れ形状の情報を活用する手段として画像認識技術に着目した。機械学習技術の中では、深層学習 (Deep Learning) を用いた畳み込みニューラルネットワーク (Convolutional Neural Network 以下、CNN) が画像認識分野において最も広く用いられている<sup>2)</sup>。このことから、ひび割れ図や横断プロフィールといった路面の損傷形状データを用いた、CNNによる舗装の構造的健全性の推定手法の構築を試みた。上述のひび割れ率とわだち掘れ量は、**図-1**のとおり算出される<sup>3)</sup>。




図-1 ひび割れ率とわだち掘れ量の算出

これは損傷の形状を、大きさだけを持つ数値 (スカラー) による指標に置き換えたものである。その際、損傷の形状に関する情報は損なわれてしまい、同じひび割れ率やわだち掘れ量でも損傷形状は異なったものとなる。CNN は画像や波形といったテンソル構造のデータがもつ座標やチャンネルといった空間的情報 (以下、空間的情報) から特徴量を抽出し判断を行う手法である。CNN を適用することで、損傷形状から構

造的健全性を推定することができるか、その適用性を検討することとした。検討に際しては、従来用いられてきた推定手法である、線形回帰やニューラルネットワークとの比較を行った。

## 2. 研究方法

### 2.1 構造的健全性の低下メカニズムと路面の関係

前述のとおり、ひび割れ率とわだち掘れ量という指標は、実際の路面に生じている現象のごく一部を数値化したものである。今回の構造的健全性推定手法の構築の前段として、路面状態と構造的健全性の関連性を整理するとともに、路盤の損傷メカニズムの典型パターンを明らかにした。それらの結果を図-2のとおり、構造的健全性の低下メカニズムと路面状態に関する体系図に反映した。図-2にあるとおり、わだち掘れと面状ひび割れが混在する場合は構造的な損傷の可能性が高いなど、路面のひび割れの特徴によって構造的健全性を推定し得ると考えた。

### 2.2 取得すべきデータの選定

このように、数値化しない状態の路面形状の情報は舗装の構造的健全性との関係が強い。このことから本研究ではひび割れとわだち掘れの形状をそのまま評価できないか思索した。

本研究における構造的健全性推定手法は、既往の研究と同様に教師あり学習を適用し、回帰モデルにて推定を行うものである。本手法は、ネットワークレベルでの適用が可能となるように、容易かつ大量に取得可能なデータを入力値とすることを想定している。そこで、路面性状データ、舗装構成、交通条件、環境条件等を入力値とし、舗装の支持力といった構造的健全性を推定するモデルの構築を図った。さらに、本モデルでは、ひび割れ形状、わだち掘れ形状といった路面の損傷形状から特徴量を抽出し、構造的健全性を推定するため、CNNの適用を検討している。CNNは画像データ等から、適切な特徴量を抽出し判断を行う技術であり、既往の研究でも多く用いられている。本モデルでは、ひび割れ形状やわだち掘れ形状といった異なる複数の画像や、設計値、条件値を説明変数とした多変量回帰の用途にCNNを用いることとしている。

### 2.3 データの取得

検証に用いるデータは、茨城県内の県道および市道の現地調査（FWD、路面性状、As コア採取）により得られたものである。調査工区は1工区200mとし、

200m区間の平均ひび割れ率が0%~60%の範囲でそれぞれ異なる12工区を選定した。12工区は全て同一市内にあり、いずれの工区も交通量区分N5相当で、気象条件も同等とみなすことができる。

本調査で取得したデータの一覧を表-1に示す。FWD調査は、1工区21点、合計252点の測定データを取得している。なお、FWD測定位置は図-3にも示す通り、外側車輪位置（OWP）とした。

路面性状調査では、ひび割れ率、ひび割れ図、ひび割れ面積率、わだち掘れ量、横断プロファイルをデータとして取得している。ひび割れ率については、FWD測定位置から評価延長5mごとに算出している。

ひび割れ図は、FWD 載荷位置を中心とした1m×1mの範囲におけるひび割れ形状をスケッチにて書き起こしたものである。さらに、ひび割れ図中のひび割れは、ひび割れ幅0~2mm、2~5mm、5mm以上の3種類で色分けされている。ひび割れ面積率は、電子画像化したひび割れ図の全面積（pixel単位）におけるひび割れの面積（pixel単位）が占める割合を算出した値である。

わだち掘れ量はFWD測定位置の横断プロファイルにより得たものである。この時の横断プロファイルを車道中央から左右に1.75mずつ取った全幅3.5mを抽出し、勾配補正したものをCNN入力用のデータとした。また、各工区の起点、中間点、終点の車道中央部にてアスファルト混合物層のコア採取を行い、各点のAs層厚を求めた。

これら252測点分のデータを学習用データと検証用データに分ける必要があるが、データの分割数については5~10分割にする場合が多い。本研究もそれに倣い252個のデータを6分割し、210個を学習用データ、42個を検証用データとした。

### 2.4 計算モデルの設定

本研究で提案しているCNNモデルの推定性能を検証するため、線形回帰モデル、NNモデルとの比較を行う。本検討では、表-2に示す4ケースについてそれぞれ $D_0$ の推定値を算出し、回帰性能の評価指標である二乗平均平方根誤差（Root Mean Square Error 以下、RMSE）と、分類性能の評価指標である正解率、適合率、検出率、にて評価を行うものとした。また各モデルとも、ランダムに選んだ210個の学習データにてモデルのパラメータを同定し、残り42個のデータを検証用として実測値と推定値の比較を行っている。

なお、線形回帰モデル、NNモデルの入力データは、ひび割れ率とわだち掘れ量であるのに対し、CNNモデ

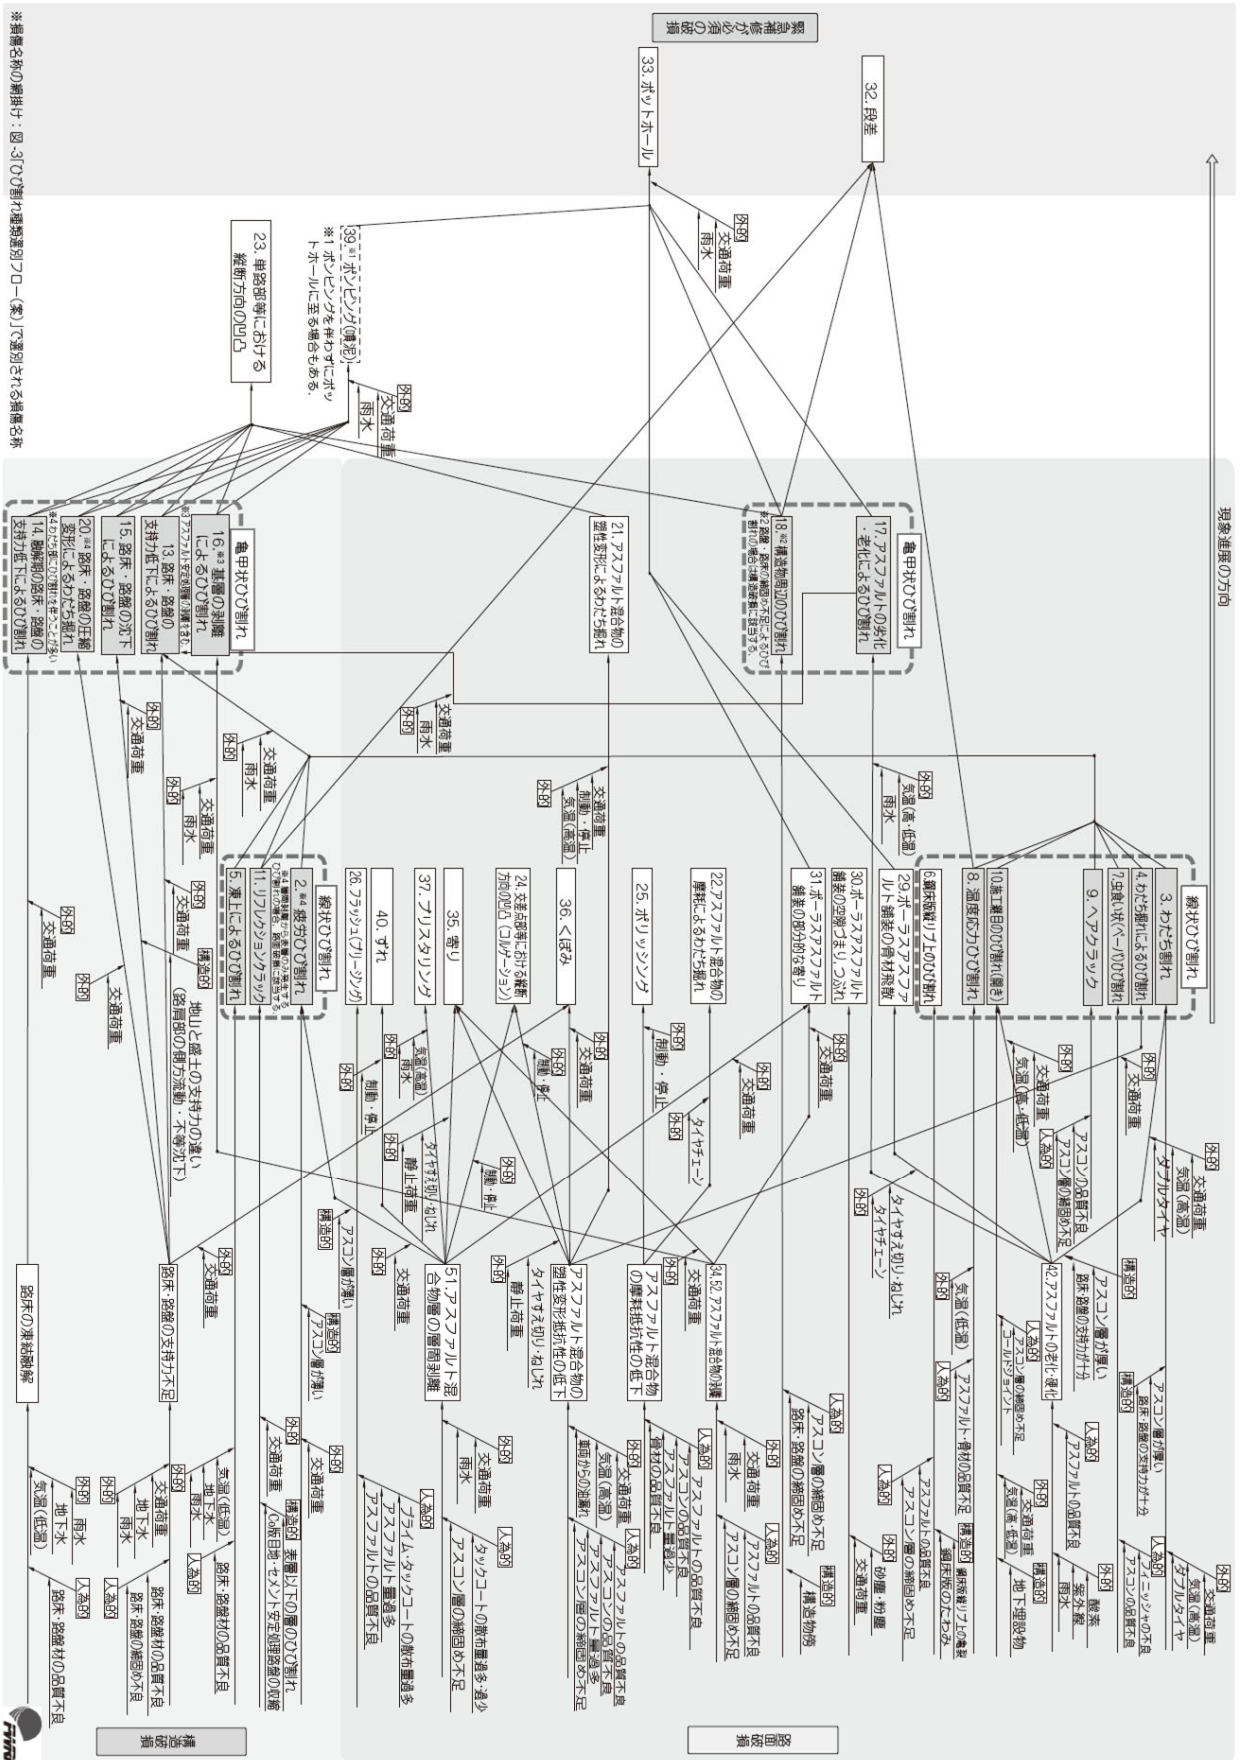


図-2 構造的健全性の低下メカニズムと路面状態の関係

表-1 取得データ一覧

測定した指標	測定手段	データの種類	解析への適用方法
ひび割れ率	路面性状測定車	数値(スカラー)	線形回帰・NNモデルの入力値(説明変数)
わだち掘れ量	路面性状測定車	数値(スカラー)	線形回帰・NNモデルの入力値(説明変数)
ひび割れ図	ひび割れスケッチ	画像(テンソル)	CNNモデルの入力値(説明変数)
横断プロファイル	路面性状測定車	波形(テンソル)	CNNモデルの入力値(説明変数)
ひび割れ面積率	ひび割れスケッチ	数値(スカラー)	解析へは未適用
As層厚さ	コアボーリング	数値(スカラー)	線形回帰・NN・CNNモデルの入力値(説明変数)
たわみ量D <sub>0</sub>	FWD	数値(スカラー)	解析の正解値(目的変数)




図-3 ひび割れ図および横断プロフィール

表-2 計算ケース

入力値	線形回帰・NNモデル				CNNモデル			
	ケースA	ケースB	ケースC	ケースD	ケースA	ケースB	ケースC	ケースD
ひび割れ	○		○	○				
ひび割れ図					○		○	○
わだち掘れ		○	○	○				
横断プロファイル						○	○	○
舗装構成	As層厚			○				○

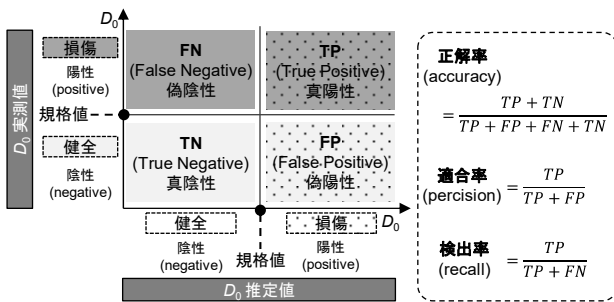


図-4 混同行列と分類性能評価指標

ルの入力データはひび割れ図と横断プロフィールであり、入力データが異なるため、単純な比較とはならない。しかし、ひび割れ率やわだち掘れ量に変換することなく元の形状データを入力値にできることが CNN の特徴であるため、今回はこの様な比較を行っている。

評価指標の RMSE は、実測値に対し推定値がどの程度の誤差を含むか示したものである。構造的健全性に関する D<sub>0</sub> の規格値を設定することで、舗装が健全か損傷しているかの 2 値に分類することができる。2 値分類器としての評価には、図-4 に示す混同行列 (confusion matrix) を用いた性能評価指標 (以下、分類性能評価指標) を用いた。この時、舗装が損傷している場合を陽性 (positive)、健全な場合を陰性 (negative) としている。なお、本調査対象道路の交通量区分が N5 であることから、D<sub>0</sub> の規格値を 0.6mm とした。

### 3. 分析結果

#### 3. 1 各モデルの推定結果

各推定モデルを用いたケース A~D における D<sub>0</sub> の推定値と実測値との関係を図-5 に示す。この結果を基に、各モデルの性能を比較していく。

#### 3. 2 RMSE による各モデルの比較結果

各ケースにおける、RMSE の算出結果を図-6 に示す。なお、D<sub>0</sub> の規格値が 0.1mm 単位であることから、RMSE の目標値は 0.1mm 程度とした。

入力値が単一のケース A およびケース B の場合、線形回帰、NN モデルとも RSME は 0.17mm と同等の値になっているのに対し、CNN モデルの RMSE は 0.11mm と他モデルより 35%程小さくなっている。

ひび割れとわだち掘れの 2 つを入力としたケース C の場合、線形回帰、NN モデルはいずれも RSME は

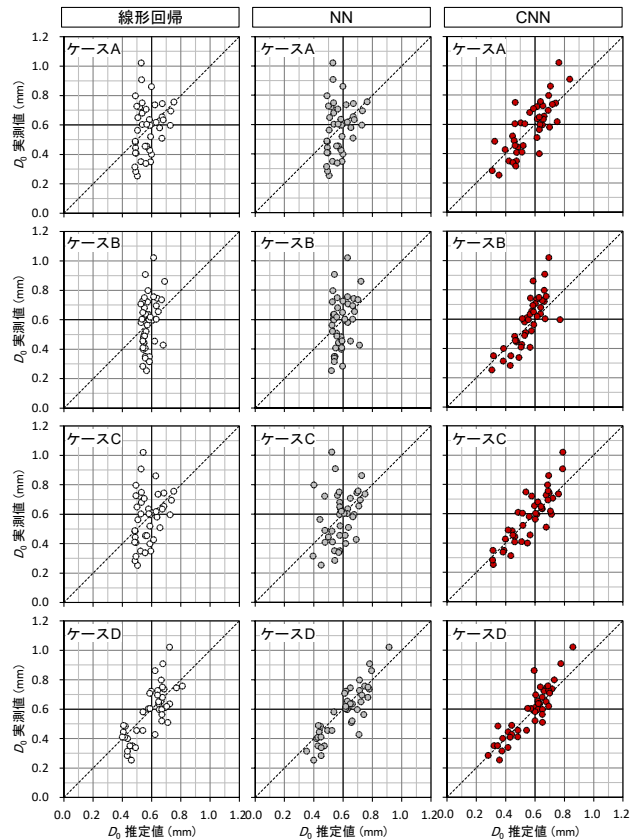


図-5 D<sub>0</sub>推定値と実測値の関係




図-6 各モデルにおける推定結果：RMSE

0.17mm であり、ケース A、ケース B に比べ RMSE の減少は見られないが、CNN モデルは 0.09mm と 18% 低減している。

さらに、As 層厚を加え、入力値が 3 つとなるケース D の場合、ケース C からの RMSE 減少量を見ると、線形回帰、NN モデルは 30~47% と大幅に低減しているのに対し、CNN モデルでは 11% であった。

### 3.3 分類性能評価指標による各モデルの比較結果

図-7 に分類性能評価指標（正解率、適合率、検出率）によるまとめを示す。正解率に着目すると、ケース A~C では CNN モデルの正解率が 70~80% と他モデルよりも 20% 程度高くなっているが、ケース D ではモデルによる差が小さくなっている。適合率に着目すると、ケース B、ケース C で CNN モデルがやや高くなっている。検出率については、ケース A~C で CNN モデルが他モデルよりも 20~30% ほど高く、ケース D では同等もしくは、NN モデルが高い結果となっている。

### 3.4 各モデルの比較結果の考察

上記の結果から、ひび割れ図や横断プロフィールといったテンソルデータは、ひび割れ率やわだち掘れ量などのスカラーデータと比べ、多くの情報を持っており、CNN により特徴量を抽出することによって、高い精度で構造的健全性を推定できるものと考えられる。また線形回帰モデルと NN モデルは As 層厚を入力とすることで、性能が向上しているが、CNN モデルではその効果が小さい。これは、ひび割れ図や横断プロフィールといったテンソルデータに比べ、スカラーデータである As 層厚の情報量が少ないことが原因の 1 つと考えられる。

また、分類性能評価指標による比較では、概ね CNN モデルが優れており、特に検出率ではモデル間の差が大きくなっている。実務において本推定技術は、ネットワークレベルでの損傷箇所のスクリーニング、といった用途での使用が考えられる。この場合、検出率の高さが求められるのに対し、CNN は少ない入力値で高い検出率をもつ手法であるといえる。しかし、ケース D においては、上記にも述べた通り、各モデルの差があまり見られていない。今回は回帰モデルにて 2 値分類を行ったが、CNN の活性化関数や評価関数を変更し（例えば、活性化関数にシグモイド関数、評価関数に交差エントロピー誤差関数など）、分類型のアーキテクチャに再構築することで分類性能は向上するものと考えられる。




図-7 各モデルにおける分類結果：  
正解率(上)、適合率(中)、検出率(下)

## 4. まとめ

路面の状態と舗装の構造的損傷の関係を考慮した点検手法の構築を目的として、路面の損傷形状に関する情報と、機械学習を組み合わせることにより、新たな構造的健全性の推定手法を構築した。この CNN を用いた推定手法は、従来の管理指標では包含されなかった損傷形状に関する情報を持つひび割れ図や、横断プロフィールデータを入力値とすることで、ひび割れ率やわだち掘れ量を入力値とする従来手法の線形回帰や NN よりも高い推定性能を持つことが確認された。また、その推定性能は、学習データの持つ目的変数の範囲内における内挿に限られ、外挿時には推定の誤差が大きくなることが明らかとなった。

本結果は、CNN が点検用途だけでなく、構造的健全性の把握といった、より高度な処理への適用性を示唆するものであり、CNN は点検診断業務の迅速化・省力化に資する手法であると言える。

## 参考文献

- 1) 国土交通省：舗装点検要領，2016
- 2) 独立行政法人情報処理推進機構：AI 白書 2017 第 1 章技術動向，2017
- 3) 日本道路協会：舗装調査・試験法便覧（平成 31 年版），丸善出版，2019
- 4) 永塚竜也，前川亮太，藪雅行：アスファルト舗装の損傷とその要因の体系図（案），舗装，Vol.55，pp.42-49，2020.5
- 5) 日本道路協会：舗装点検必携，丸善出版，2017
- 6) 渡邊一弘，久保和幸：アスファルト舗装のひび割れに関する新たな評価指標の提案，土木技術資料，Vol.52，No.11，pp.32-35，2011

# A STUDY ON PAVEMENT DETERIORATION MECHANISM AND SURFACE CONDITIONS

Research Period : FY2018-2020

Research Team : Water Environment Research  
Group(Water Quality )

Author : YABU Masayuki

WATANABE Kazuhiro

IWANAGA Masakazu

KAWAKAMI Atsushi

MAEKAWA Ryota

NAGATSUKA Tatsuya

Abstract : The technical standard for pavement inspection in Japan attaches importance to structural soundness of subbase layer and below. The authors have built a new way to evaluate structural soundness without traffic restrictions. This evaluation way uses crack shape, rut shape, and machine learning method (convolutional neural network:CNN). Deflection D0 was estimated using the crack diagram, cross-sectional profile and asphalt layer thickness. This evaluation way estimated the deflection D0 with higher accuracy than the conventional method using cracking ratio and rut depth.

Key words : Pavement deterioration, surface condition, FWD deflection, Convolutional Neural Network