

舗装維持管理効率化のためのニューラルネットを用いた路面性状値予測の検討

奥田 知之[†] 黒須 秀明[‡] 神武 直彦[†]

慶應義塾大学大学院 システムデザイン・マネジメント研究科[†] 株式会社パスコ 研究開発本部[‡]

1 はじめに

近年の少子高齢化・経済の停滞により社会資本を適切に維持管理していくコストが賄えなくなるといわれており、効率的に維持管理することが求められている。本研究では社会資本の1種で比較的更新頻度が高く、定量的なデータが蓄積されている舗装維持管理に着目した。

舗装の劣化を予測するためには主に①～③の方法がある。

- ① 自動車と舗装間の力学的な応答を定式化する方法[1]。路面性状に加え全路線の弾性や地下空洞などのデータを計測するコストがかかる。
- ② 力学的な応答は考慮せず確率的なデータの生成過程をモデリングする方法[2]。予め決めたモデルに依存するため、現実からの乖離が大きい。
- ③ 直接データから結果を予測する関数を作成する方法。重原ら[3]は、入力データとしてIC間の位置情報や、交通量等を採用し、ニューラルネットにより高速道路(北陸自動車道)わだち掘れ量を予測するモデルを構築できることを示した。

本研究では道路設計や定期点検時等に記録された既存データを使用した。既存データを活用するために、柔軟な入力データから複雑な条件を学習できるニューラルネットを使用した。それにより路面性状3項目(ひび割れ・わだち掘れ・平坦性)の予測を検討した。

2 NNの構成

ニューラルネットフレームワークのchainer[4]を使用した。モデルは12層の順伝播型ネットワークで、中間層のユニット数は全て100、活性化関数には正規化直交関数を用いた。誤差関数は2乗誤差で、最適化にADAMを用いた。

ひび割れ・わだち掘れ・平坦性を別々のネットワークで学習した。出力層はひび割れ・わだち掘れ平坦性のいずれか1ユニットである。

Road surface property value prediction using neural net for pavement maintenance efficiency.

[†]Graduate School of System Design and Management Keio University

[‡]PASCO Research & Development HQ

入力には交通量や路面種別(アスファルトかコンクリートか)等のデータを使用した(表1)。

わだち掘れ、ひび割れの学習データ数はおよそ30,000件、テストデータは3,000件、平坦性の学習データは10,000件、テストデータは1,000件である。ダミー変数以外の入力データは正規化した。

3 データ処理

3.1 ダミー変数化

入力データ項目の構造物や交差点など、名義尺度の項目をダミー変数化した。

3.2 欠損データの存在

入力データには欠損があるので、欠損しているニューロンに接続する重みは更新しない事とした[5]。入力データの欠損値は値を0とし、ドロップアウトと同様の考え方で0入力の割合だけ層の出力データを(1)式のように修正した。

$$\mathbf{X}' = \frac{n}{n-c} \mathbf{X} \quad (1)$$

ここで、 \mathbf{X} は入力値、 \mathbf{X}' は修正後の入力データ、 n は入力データ数、 c は欠損データ数である。

3.3 補修データの正確性

路面性状値は補修があれば改善する。補修は計画と実施が異なる事が多々ある。しかし補修履歴には実施時の変更点が記録されていない等の原因により、正確性が低い。

補修後経過年数を正しく算出するために、わだち掘れ、ひび割れ、平坦性の各値が著しく

表1 入力データ項目

入力データ項目	内容
路面種別	コンクリート又はアスファルト
大型車交通量	大型車交通量
CBR(路床の支持力)	道路設計時の路床の支持力
最新補修工法	最後に行われた補修の工法
補修後経過年数	補修(又は新設)後の経過年数
調査年度	教師データの調査年度
舗装構成	上層、中層、下層の厚さ
構造物	橋、トンネル等
交差点	交差点を含むか含まないか
幅員	道路幅員
初期路面性状値	補修後最初に計測されたひび割れ・わだち掘れ・平坦性の各値

改善した(1/2 以下)場合, 補修があったと判断した. 式にすれば

$$f(u) = \begin{cases} 1(u < 0) \\ 0(u \geq 0) \end{cases} \quad (2)$$

$$g(x_i) = 2x_i - x_{i-1} \quad (3)$$

としたとき, 次の(4)式が成立するときに補修が行われたと判断した.

$$f(g(RD_i)) + f(g(CR_i)) + f(g(SV_i)) \geq 2 \quad (4)$$

ここで, RD_i, CR_i, SV_i は時間ステップ i におけるわだち掘れ, ひび割れ, 平たん性の値を表す.

補修経過後年数を補修履歴から作成した場合と, (4)式から補修を判断して作成した場合の各2乗誤差を表2に示す. 結果として補修履歴から補修を判断するよりも精度は低かった. 原因の1つは, 調査が不定期である事が上げられる. 場所により10年以上同じ個所の計測データが無い事がある. 今回, (4)式で補修されたと判断された箇所は, その年度(時間ステップ i)を補修年度としている. したがって実際の補修年度と差がある.

表2 補修後経過年数による2乗誤差
値は最終10エポックの平均値である.

	補修履歴から	(4)式の条件
わだち掘れ	11.6	11.0
ひび割れ	14.2	19.4
平たん性	93.4	109.1

表3 予測-実測の相関係数

項目	補修履歴から	(4)式の条件
わだち掘れ	0.5392	0.5186
ひび割れ	0.5225	0.3455
平たん性	0.5830	0.4920




図 平たん性予測-実測比較

4 結果

テストデータを用いて平たん性のニューラルネットワークモデル出力を x 軸, 教師データを y 軸にプロットした(図).

比較的平たん性の相関が高いが, 値の大きい箇所でも過小評価している. ひび割れ, わだち掘れについても同様に過小評価の傾向が見られた.

5 まとめと今後の課題

路面性状データを順伝播ニューラルネットワークによって予測した. 欠損のあるデータで学習が可能なが解った.

補修履歴の正確性が低い事が解っているため, 補修の判断をデータから行う事を試みたが, 精度は向上しなかった. 例えば補修履歴の信頼できない箇所を判断し, そこだけデータから補修の判定をする等の対応が必要である.

学習データ面で予測精度を向上するためには, 舗装の劣化に深く関わる温度や水の入力データを加えるべきである. また, データの白色化を行う事や, 他の地方のデータを使用して学習する事, 今回使用した 50m で平均されたデータではなく 5m 単位のデータを使用する事等が必要である. また, 年度によって, 計測する車両によって路面性状値の傾向が変わる事があるため, その補正を入れる必要がある.

モデル面で予測精度を向上するには, 過去の履歴を記憶できる再帰的ニューラルネットワークを用いる等が考えられる.

6 参考文献

- [1] Baus, R. L., & Stires, N. R., Pavement Design Guide Implementation, 29208(803), 2010
- [2] 貝戸清之, 小林潔司, 青木一也, 松岡弘大, 混合マルコフ劣化ハザードモデルの階層ベイズ推計, 土木学会論文集 D3 (土木計画学), 68(4), 255- 271, 2012
- [3] 重原大二朗, 西澤辰男, 中源達雄, 平野誠志, ニューラルネットワークによる北陸地方のアスファルト舗装わだち掘れ進行モデル, 土木学会舗装工学論文集第13巻2008年12月
- [4] Seiya Tokui, Kenta Oono, Shohei Hido and Justin Clayton, Chainer: a Next-Generation Open Source Framework for Deep Learning, in Neural Information Processing Systems, Workshop on Machine Learning Systems, 2015
- [5] 市川紘, ニューラルネットワークの情報処理におけるデータ欠損の取り扱い, 情報化学討論会・構造活性相関シンポジウム講演要旨集, 25-30, 192-195, 2002