

# 予測メンテナンスとインフラ劣化学習モデル

## Infra Machine Learning for Predictive Maintenance via Classification Models

安野 貴人<sup>\*1</sup>  
Yasuno Takato

<sup>\*1</sup> 八千代エンジニアリング株式会社  
Yachiyo engineering, Co., Ltd.

Aging infrastructure that was developed during the period of high growth is beginning to become obvious. Visual inspection and sensing are carried out to monitor the state of deterioration in preventive maintenance. It is the standard procedure in Japan that bridges with important structures are inspected once in five years where they visually check the proximity. A high accuracy and efficiency improvement of the bridge inspection is an urgent issue for the both local public municipalities and private enterprises. This paper proposes multi-grade classification models to visualize the weights of feature variables that aim the countermeasure. In addition, the author proposes a method of sensitivity analysis on deterioration progression in the future in response to unit change of degradation factors. Indeed, these methods applied to a bridge inspection data such as super structure steel corrosion and deck reinforced concrete crack.

### 1. はじめに

高度成長期に整備したインフラ施設の老朽化が顕在化し始めている。予防保全における劣化の状態監視のために、目視点検やセンシングが行われている。重要構造物である橋梁は、5年に1回の頻度で近接の目視を行う点検要領が基準となっている。地方公共団体、民間事業者に関わらず、橋梁点検の高い精度と効率化は喫緊の課題である。本稿では、点検データを用いた多クラスの劣化判別モデルを提案する。これにより、劣化の要因となる特徴変数の重みを視覚化し、対策の照準を合わせることが可能となる。特徴変数の単位変化に対応して今後の劣化進行に関する感度分析の方法を提案する。実際に、橋梁部材の点検データに適用した結果を考察する。

### 2. 劣化学習モデル

#### 2.1 予測メンテナンスのためのインフラ劣化学習

インフラの点検を効率化するための点検・モニタリング・診断技術に関しては、例えば、社会インフラの維持効率を向上する施設モニタリングサービス[日立 2014]、社会インフラメンテナンスの技術開発の方向性[土木学会 2017]、インフラ維持管理アセットマネジメント[COCN 2017]、戦略的イノベーション創造プログラム[SIP 2017]、コンクリート内部の鉄筋腐食検査[生嶋 2017]、河川堤防の変状検知[佐古 2017]等、多数の技術研究が見られる。また、予測メンテナンスや故障解析の機械学習プロセスに関しては、例えば、製造プロセスの予知保全の解析技術[MathWorks]、予測メ

ンテナンス方法の提案[Kaggle 2017]、プラントメンテナンスのタスク自動化テンプレート[Excel Templates]等の製造業の生産プロセスにおける提案が多くみられる。しかし、インフラ施設を対象に、目視点検やモニタリングのデータを用いて、インフラの劣化状態を自動判定し、さらに、今後の劣化傾向の予測をいかに行うかという老朽化対策の基盤となるモデル（以下、「インフラ劣化学習モデル」と呼ぶ）が確立されたとは言い難い。本稿では、インフラ施設の点検データを用いた多クラスの劣化判別モデルと特徴変数の変化に対する劣化状態の感度分析の方法を提案する。

#### 2.2 劣化状態の判別モデル

##### (1) 劣化状態の多クラス判別モデル

インフラ劣化学習のために、劣化状態が2~5段階である多クラスの判別を可能とする実践的なアルゴリズムをリストアップする。まず、汎用性がある一般化線形モデルGeneralized Linear Model (Multinomial family) に着目した[McCullagh 1983] [Hardin 2012]。機械学習の典型的なアルゴリズムNaïve Bayes, Decision Tree (以下,DTという), k-NN, Support Vector Machine (以下,SVCという), Neural Networkに着目した[Hastie 2009] [Efron 2016]。また、アンサンブル手法のRandom Forest [Breiman 1998, 2001]に加え、Gradient Boosted Machineに着目した[Friedman 2001] [Scholkopf 2012]。これら8つのアルゴリズムは、scikit-learn[Muller 2016], H2O[Cook 2016], MLTK[Murphy 2012], Rapid Miner[Hofmann 2014]のリソースを用いて迅速に数値計

連絡: 安野貴人, 技術開発部, 〒111-8648 東京都台東区浅草橋 5-20-8 CSタワー, tk-yasuno@yachiyo-eng.co.com

算が可能であり、それ自体に新規性はない。本稿では、インフラ劣化学習モデルの実践を追求するため、それらの学習精度と計算時間等の有用性を比較する。

## (2) 劣化の特徴変数のシナリオと劣化状態の感度分析

劣化の特徴変数の単位変化に対して、今後の劣化が加速するか減速するかという感度分析の方法を提案する。インフラ施設の諸元や規模、設置条件の外部環境は、大規模改修や更新をしない限り竣工時点から所与の特性である。点検時点から今後、起こりうる特徴変数の変化は、経年変化に伴う老朽化、修繕対策の実施の有無と対策時期が早い遅いかである。5年間のスパンで、時間の経過はもちろん、修繕の実施は、対処可能なシナリオである。以下では、他の条件を所与として、1) 今後5年先の姿、経過年数が増えるケース、2) 修繕を実施する年を早めるか、後方にするかのケースを劣化の特徴変数のシナリオに設定する。機械学習のモデルは、帰納的に計算して精度を高める利点がある。しかし、感度分析には、幾分の精度を犠牲にしても、劣化の特徴変数を単位変化させるパラメトリックな操作を行い、劣化状態のクラスがより進行するか、あるいは延命するかの変化を傾向把握したい。

一般化線形モデル Generalized Linear Model (Multinomial family, 以下, GLM という) は、劣化状態のクラスと劣化要因となる特徴変数との間に、線形の関係性を明示的に考慮できる。以下では、GLMを基盤に、経過年数と修繕実施の単位変化による劣化傾向の変化をシナリオ分析することとする。

## 3. モデル計算結果

### 3.1 劣化データと特徴変数

本稿では、橋長100m以上の橋梁195において、1988年から5年ごとに4回 (I ~ IV)、近接目視を行った損傷データ (主桁-鋼材-腐食4,864単位、床版-RC-ひび割れ8,778単位) を対象とする。近接の目視では、劣化の状態a,b,c,d,eによる5段階の判定を行った。劣化を説明する特徴変数は150変数である。内訳は、竣工年、橋長、上部工の形式、橋桁高さ、示方書の年次の橋梁諸元データに加え、海岸からの距離、桁下河川等、大型交通量の設置条件、点検時点の経過年数と径間別の健全度等の点検属性、塗装系や点検前の補修工事の有無、修繕工種等の修繕履歴で構成される。目視点検データの特性は、健全な状態a,bの割合が多く、c,dの割合が少ないというインバランスなデータである。なお、耐用限界に近い状態まで放置するこ

とがないため、e判定のデータは数単位 (腐食5、ひび割れ1) であった。本計算では、劣化状態a,b,c,dの4クラス判別モデルを学習する。時系列の特性は、5年に1回の頻度で4回点検した点検パネルデータである。劣化状態の判定は、点検士が行いラベルを割り当てる。毎回、同じ点検士が行うとは限らず、人の判断にぶれや無難な判断への歪み等のノイズが含まれる可能性がある。

表1 主桁-鋼材-腐食の4クラス判別モデルの交差評価

Steel Corrosion Classification Models	Accuracy (percent)	Correlation	Running time
Generalized Linear Model (Multi-nomial function)	75.36+/-1.24	0.610+/-0.022	5s
Naïve Bayes (Kernel density estimation, knum=10, bandw=0.3, grid=200)	64.69+/-2.87	0.365+/-0.050	<1s
k-Nearest Neighbor (k=3)	81.20+/-1.07	0.616+/-0.018	4s
<b>Support Vector Classifier</b> (Radial basis function, gamma=0.7, C=4.0)	<b>81.20+/-0.73</b>	<b>0.683+/-0.030</b>	26s
Deep Neural Network (hidden layers=2, 150 × 150units, Dropout=0.5, epoch=200)	79.22+/-1.26	0.626+/-0.030	2m13s
Decision Tree (max depth=50)	70.63+/-3.00	0.583+/-0.034	2s
Random Forest (ntree=100, max depth=47)	78.44+/-0.89	0.622+/-0.040	31s
<b>Gradient Boosted Machine</b> (ntree=200, max depth=50)	<b>82.49+/-0.91</b>	<b>0.672+/-0.014</b>	2m11s

表2 床版-RC-ひび割れの4クラス判別モデルの交差評価

Reinforced Concrete Crack Classification Models	Accuracy (percent)	Correlation	Running time
Generalized Linear Model (Multi-nomial function)	67.89+/-0.47	0.502+0.013	7s
Naïve Bayes (Kernel density estimation, knum=10, bandw=0.3, grid=200)	61.11+/-2.72	0.411+/-0.47	1s
k-Nearest Neighbor (k=3)	80.61+/-0.91	0.716+/-0.20	8s
Support Vector Classifier (Radial basis function, gamma=0.65, C=4.0)	81.43+/-0.83	0.718+/-0.020	30s
Deep Neural Network (hidden layers=2, 150 × 150units, Dropout=0.5, epoch=200)	79.71+/-0.87	0.688+/-0.012	4m14s
<b>Decision Tree</b> (max depth=60)	<b>82.49+/-1.06</b>	<b>0.739+/-0.020</b>	2s
Random Forest (ntree=100, max depth=59)	78.72+/-0.36	0.713+/-0.014	34s
<b>Gradient Boosted Machine</b> (ntree=260, max depth=65)	<b>82.87+/-1.09</b>	<b>0.743+/-0.018</b>	5m4s

### 3.2 劣化学習の計算結果

表1と表2に、主桁-鋼材-腐食及び床版-RC-ひび割れのデータに8つのアルゴリズムを適用した結果を示す。Cross Validation (交差評価) では、劣化状態別の階層サンプリングにより5-foldの評価を行った。このなかで、最高の精度を示したのは、Gradient Boosted Machine (以下, GBMと表す) である。主桁-鋼材-腐食は、Accuracy 82.49+/-0.91%、実績と予測との相関係数 0.672+/-0.014の評価を得ている。また、床版-RC-ひび割れの学習結果は、Accuracy 82.87+/-1.09%、実績と予測の相関係数 0.743+/-0.018の評価を得ている。

表 3 Gradient Boosted M.Confusion Matrix (主桁-鋼材-腐食)

	true a	true b	true c	true d	precision
pred. a	2444	313	61	11	86.4%
pred. b	267	1350	53	19	79.9%
pred. c	48	48	202	3	67.1%
pred. d	6	19	3	18	39.1%
recall	88.4%	78.0%	63.3%	35.3%	

表 4 Gradient Boosted M.Confusion Matrix (床版-RC-ひび)

	true a	true b	true c	true d	precision
pred. a	3020	333	88	34	86.9%
pred. b	415	2988	196	50	81.9%
pred. c	54	156	1027	29	81.1%
pred. d	17	63	34	265	69.9%
recall	86.1%	84.4%	76.4%	70.1%	

表 3 と表 4 に、主桁腐食及び床版ひび割れに関する GBM の Confusion Matrix を示す。主桁腐食の d 判定は 50 単位以下のデータの少なさから、精度 39.1%、再現率 35.3%が低い。床版ひび割れ d 判定 (300 以上) は、精度 69.9%、再現率 70.1%と良好な結果を得た。特に、a,b,c 判定と予測したが、実際に d 判定となる予測誤差 (true d 列) は、最小化しなければならない。この問題は、予測誤差に対するコストの感度を明示的に考慮した判別モデルの再学習が可能である [Yasuno 2018]。

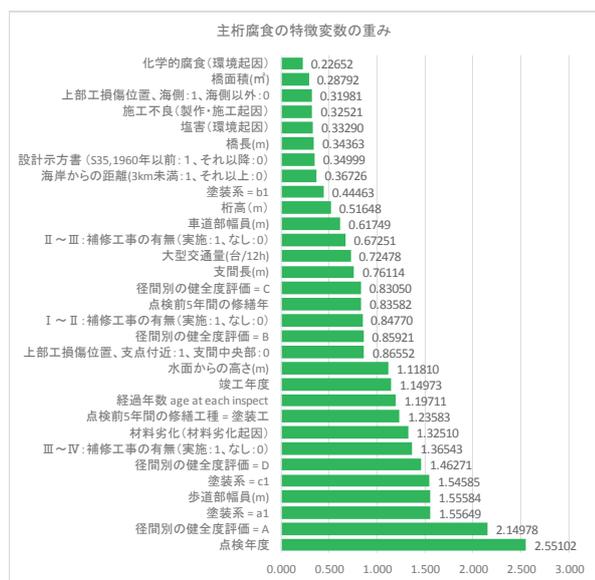


図 1 主桁腐食の特徴変数の重み (GLM: Multinomial family)

図 1 に、GLM の主桁腐食の劣化学習に用いた特徴変数 150 のうち上位 30 の重みを昇順に図示した。主桁-鋼材の腐食には、1) 点検年、竣工年、点検時の経過年数という時間軸の経

年変化、2) 水面からの高さ、海岸からの距離 (3km 未満) という橋梁が置かれた外部環境、3) 点検前 5 年間ににおける補修工事の有無、修繕工種 (塗装工)、修繕の実施年 (西暦) という修繕履歴、4) 歩道幅員、支間長さ、橋長、橋面積、大型交通量という橋梁の規模、5) 塗装系、損傷の位置 (海側、支点、支間中央)、径間別の健全度という損傷部材の特性、6) 材料劣化、塩害・化学的腐食 (環境起因) という特徴変数が劣化状態のクラス判別に働いていることが読み取れる。

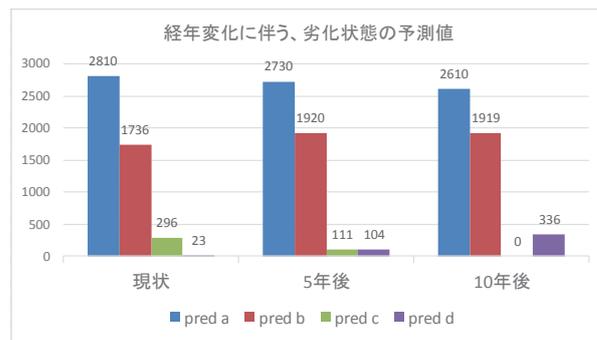


図 2 経過年数の変化に対する主桁腐食の劣化状態の予測値さらに、主桁腐食の特徴変数を変化させた場合の劣化状態の予測値の感度分析を行った計算結果を示す。図 2 に、経過年数と点検年度の特徴変数を 5 年後、10 年後と増加させた場合の劣化状態の予測値の変化を図示した。経年変化に伴い、健全な a 判定の数が減少し、c 判定の数が減少する代わりに、d 判定の数が増加する劣化傾向が表現されている。

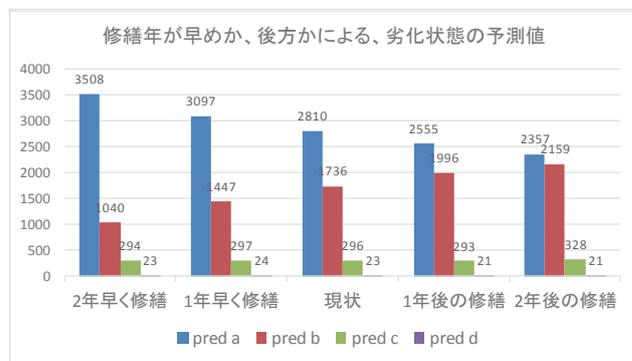


図 3 塗装修繕を早めるか遅くするかに対する劣化状態の予測

図 3 に、塗装修繕の年次を 1~2 年、早くするか、あるいは遅くするかに対して、劣化状態の予測値を算出した結果を図示した。早く修繕する場合に、b 判定の数が減少する代わりに a 判定の数が多くなる。予防的修繕は、劣化状態を加速させずに、回復するか延命して劣化にブレーキをかける状況が表現されている。一方、遅く修繕すると a 判定の数が減少し、b 判定の数が増加している。c 判定の劣化状態は、ほとんど変化がないものの、最も遅く 2 年後の修繕にした場合に限り、他の条件よりも劣化状態が増発する結果となっている。

#### 4. おわりに

本稿では、インフラ劣化学習のために、管理者が定期的に収集する点検データを用いて、多クラスの劣化状態を判別するモデルを提案した。主桁鋼材腐食の精度は、GBM 82.49%、SVC 81.20%の評価を得た。床版 RC ひび割れの精度は、GBM 82.87%、DT 82.49%の評価を得た。レアな c,d 判定のデータ蓄積が進めば DT も迅速な計算ができて有望と言える。精度が 82% で頭打ちした理由は、目視点検データは人がラベルを貼った結果であり、判断のぶれや歪みのノイズが 18% 残ると解釈できる。この劣化学習のノイズを最小化する必要がある。さらに、GLM を基盤に、特徴変数の単位変化に対して、劣化クラス予測値の感度分析法を提案した。経年変化により劣化傾向が加速するか、あるいは、早めの予防修繕により劣化を減速できるか、または遅い事後修繕により劣化が増発する恐れがあるかの短期の劣化予測が可能となった。実際に、主桁-鋼材-腐食と床版-RC-ひび割れの 2 つの点検データを対象に、a,b,c,d の 4 クラスの判別モデルを劣化学習し、各モデルの計算結果から精度と計算時間を比較した。

今後の課題に言及する。本稿では、提案したインフラ劣化学習のモデルを橋梁の主桁-鋼材-腐食及び床版-RC-ひび割れの一定期間のデータセットに適用し、GBM,SVC,DT の 3 つの有望なモデルが得られた。今後、橋脚や支承等の異なる部材に応用範囲を広げることが可能と考える。他のインフラ施設においても鋼製腐食やコンクリートひび割れは、頻繁に現れる。今後、オンラインの連続監視とデータマイニングの機会を捉え、早期劣化や施工品質等の異常なクラスの検知を含めて、インフラ劣化学習モデルの実用新案に挑戦する。現状では、近接目視の判定は、損傷画像に着目し点検士が 5 段階のラベルを貼っている。CV の画像処理[Prince 2012] と転移学習[Geron 2017]を進めれば、劣化学習のノイズを縮小できると考える。今後、劣化学習モデルのバリエーション拡充と予測メンテナンスの資質向上と普及啓発に努めたい。

**[謝辞]**yec にて、インフラ劣化学習のプロトタイピングと技術研鑽の機会を得たことに感謝の意を表します。

#### 参考文献

[日立 2014] 萩原正樹, 上松正史他: 社会インフラの維持効率を向上する施設モニタリングサービス, 社会インフラセキュリティ, Vol.96, No.3, pp190-191, 2014.  
 [土木学会 2017] 土木学会社会インフラメンテナンスシンポジウム, これからの社会インフラメンテナンスの技術戦略, 2017.1.  
 [COCN 2017] 産業競争力懇談会: インフラ維持管理アセットマネジメント, 2017.2.  
 [SIP 2017] 戦略的イノベーションプログラム SIP, (1)点検・モニタリング・診断技術, 2017.

[生嶋 2017] 生嶋健司他: コンクリート内部の鉄筋腐食検査装置の開発, SIP (1)6, 2017.  
 [佐古 2017] 佐古俊介他, 河川堤防の変状検知等モニタリングシステムの技術研究開発, SIP (1)30, 2017.  
 [MathWorks] MATLAB: 予知保全の解析技術, 予知保全のユーザー事例, 予知保全システムの構築.  
 [Kaggle 2017] Kocaman, V.: Predictive Maintenance with GBoost, kaggle, 2017.  
 [Excel Templates] Maintenance Planning and Scheduling, Excel Templates for Plant Maintenance.  
 [McCullagh 1983] McCullagh, P. and Nelder, J.: *Generalized Linear Models*, Monographs on Statistics and Applied Probability, Chapman & Hall, 1983.  
 [Hardin 2012] Hardin, J.W. and Hilbe, J.M.: *Generalized Linear Models and Extensions 3<sup>rd</sup> edition*, Stata Press, 2012.  
 [Hastie 2009] Hastie, T., Tibshirani, R. and Friedman, J. : *The Elements of Statistical Learning ; Data Mining, Inference and Prediction*, 2<sup>nd</sup> edn. Springer, 2009.  
 [Efron 2016] Efron, B. and Hastie, T.: *Computer Age Statistical Inference: Algorithms, Evidence and Data Science*, Cambridge Univ. Press, 2016.  
 [Breiman 1998] Breiman, L.: Arcing Classifiers (discussion), *Annals of Statistics*, 26, pp.801-849, 1998.  
 [Breiman 2001] Breiman, L.: Random Forests, *Machine Learning*, 45, pp.5-32, 2001.  
 [Friedman 2001] Friedman, J.: Greedy Function Approximation: A Gradient Boosting Machine, *Annals of Statistics*, 29(5), pp.1189-1232, 2001.  
 [Scholkopf 2012] Scholkopf, B. and Freund, Y.: *Boosting: Foundations and Algorithms*, MIT Press, 2012.  
 [Muller 2016] Muller, A.C. and Guido, S.: *Introduction to Machine Learning with Python: A Guide for Data Scientists*, O'Reilly, 2016.  
 [Cook 2016] Cook, D.: *Practical Machine Learning with H2O: Powerful, Scalable Techniques for Deep Learning and AI*, O'Reilly, 2016.  
 [Murphy 2012] Murphy, K.P.: *Machine Learning: A Probabilistic Perspective*, MIT Press, 2012.  
 [Hofmann 2014] Hofmann, M., Klinkenberg, R.: RAPID MINER: Data Mining Use Cases and Business Analytics Applications, *Data Mining and Knowledge Discovery Series*, CRC, 2014.  
 [Prince 2012] Prince, S.J.D.: *Computer Vision: Models, Learning, and Inference*, Cambridge Univ. Press, 2012.  
 [Geron 2017] Geron, A.: *Hands-On Machine Learning with Scikit-Learn & TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*, O'Reilly, 2017.  
 [安野 2007] 安野貴人, SHM による劣化予測, コンクリート構造物のヘルスマニタリング, コンクリート技術 76, 土木学会, 2007.  
 [安野 2007] 安野貴人他, 土木構造物の維持管理と劣化進行のハザード形状, 応用力学論文集 Vol.10, 2007.  
 [Yasuno 2010] Yasuno, T.: Neighbor-Park Management Method to Both Smoothen Long-run Budget and to Precaution Early-Deterioration Equipments, *Social Management Systems*, 2010.  
 [Yasuno 2018] Yasuno, T.: Dam Inflow Time Series Regression Models for Minimizing Loss of Hydro Power, *Data Mining for Energy Modeling and Optimization* (Forthcoming).  
 (2018.3.16)