

## AI を活用した管路老朽度診断に用いる

### 漏水実績データに関する考察

株式会社 NJS ○角田里奈 馬場啓輔

AI を活用した管路老朽度診断を実施するにあたり、AI 学習データには漏水実績データを用いることが多い。しかし、事業者が管理するデータは、修繕工事の記録が主な目的とされ、AI 学習データとして理想的な情報が登録されているとは限らない。本稿では、漏水実績データに含まれる情報の選別条件を変え複数の診断モデルを構築し、診断結果である漏水事故率の予測精度を比較し、学習データ数とその精度の信頼性が予測精度に与える影響について考察した。本検証の結果、診断対象が送水管である場合、学習データが少なくとも確度の高い漏水実績を採用した方が優位な結果となった。

*Key Words* : 水道、AI、学習データ、老朽度診断、漏水事故率、管路更新計画

#### 1. 検討背景

##### 1.1 はじめに

近年、水道管路の更新計画策定にあたり、地震対策を除いた管路の劣化状況の更新優先度を評価する手法として、AI を活用した管路老朽度診断（以下「AI 老朽度診断」という。）を実施する事例が増加している。

AI 老朽度診断を実施する際、AI に管路の劣化傾向を学習させるためには、該当事業体で過去に発生した漏水実績データを使用する。しかし、事業者が管理する漏水実績データは、主に修繕工事の記録を目的としているため、AI 学習データとして必ずしも理想的な情報が登録されているとは限らない。さらに、ダクタイル鋳鉄管においては、本管漏水が他の管種と比較して少ないため、学習データとして十分なサンプル数が得られないケースも想定される。

本稿では、AI 老朽度診断において、「インプット」となる漏水実績データ（修繕工事記録のうち限られた情報の選定方法や、「アウトプット」となる漏水リスク（漏水事故率、漏水事故件数等）の精度検証方法が未確立である現状に着目し、複数の AI 学習データを用いた老朽度評価結果を比較し、その差異が生じた原因について考察した。

## 1.2 AI 老朽度診断における理想的な学習データとは

表-1 は AI 学習データとして理想的な漏水実績データの一覧を示す。しかし、水道事業者が主に整理している情報は、発生年や住所等といった基本情報に加え、修繕対象（管種、口径）、修繕日及びコメント（漏水通報者情報、修繕工事業者名等）といった修繕記録のみにとどまっていることが多い。

AI 老朽診断の学習データとして必要な情報は、口径や布設年、材質、継手といった既設管の基礎情報に加え、事故要因（劣化による事故が区別できる内容）、対応種別（修繕／更新）、対応状況及び座標情報であり、現況の修繕記録の情報だけでは、これらのデータが不足しているのが実態である。

特に、漏水事故位置の座標情報は、GIS で整理された管路データと漏水発生箇所との正確なマッチングのために必須であり、座標情報がない場合は、住所等の情報から近傍の管路を想定せざるを得ないケースが生じる。さらに、同じ管種、口径が集中しているエリアでは、該当管路の特定が一層困難となる。

また、管路の布設年度や対応種別（修繕／更新）の情報は、GIS データと照合する際に、その漏水事故が発生した管路が最新の GIS データ上に存在する管路であるのか、更新（布設替え）され現存しない管路であるかの判断をするために重要な情報である。

表-1 AI 学習データとして理想的な漏水実績データ（例）

	項目	摘要	事業者において主に記録されている情報
必須	事故ID	漏水事故発生箇所数分の個別ID	
	事故発生年[年]	1999、2003、2012 等 ※西暦	○
	住所	○市○丁目○番地 等	○
	口径[mm]	75、150、300 等	
	布設年[年]	1954、1980、2010 等	
	修繕対象	配水管、水管橋、送水管、給水管 等	○
	管材質	DIP、SP、VP 等	
	継手	K、溶接、RR 等	
	事故要因	腐食、パッキン劣化、地震、不等沈下、他事故起因 等	
	対応種別	修繕／更新	
	座標	緯度、経度 ※マッピングデータ形式	
推奨	防食仕様	ポリエチレンスリーブ有無 等	
	事故発生箇所	直管部、継手、空気弁 等	○
	漏水状態	穴あき、亀裂、折損 等	○
	修繕日	○月×日 等	○
	配管図番号	a00001、a00002 等	
	コメント	住民通報にて発見、○○で修繕… 等	○
維持管理、 計画策定に有効	漏水量 [m3/h]	50、30、2… 等	
	断水戸数 [戸]	200、30、5… 等	
	断水時間 [h]	24、15、10…等	
	近隣埋設物	ガス管 等	

## 2. AI 老朽度診断モデルの概要

### 2.1 事業者独自モデルの構築

AI 老朽度診断にもちいるモデル構築のイメージを図-1 に示す。

まず、全国の漏水実績データや管体調査データ等を用いて、ダクタイル鉄管及び铸铁管の老朽化に影響を与える埋設環境の腐食性を機械学習により 4 つに分類したマップを作成し、診断対象の管路データを照合させ、「全国汎用版モデル」を構築した。アウトプットは、老朽化によるリスクを漏水事故率 [件/年/km] として算出する。

次に、この全国汎用版モデルに、対象となる水道事業者の漏水実績データを追加で学習させ、その事業者特有の状況を反映した「事業者独自モデル」を再構築し、漏水事故率の予測精度の向上を図った。

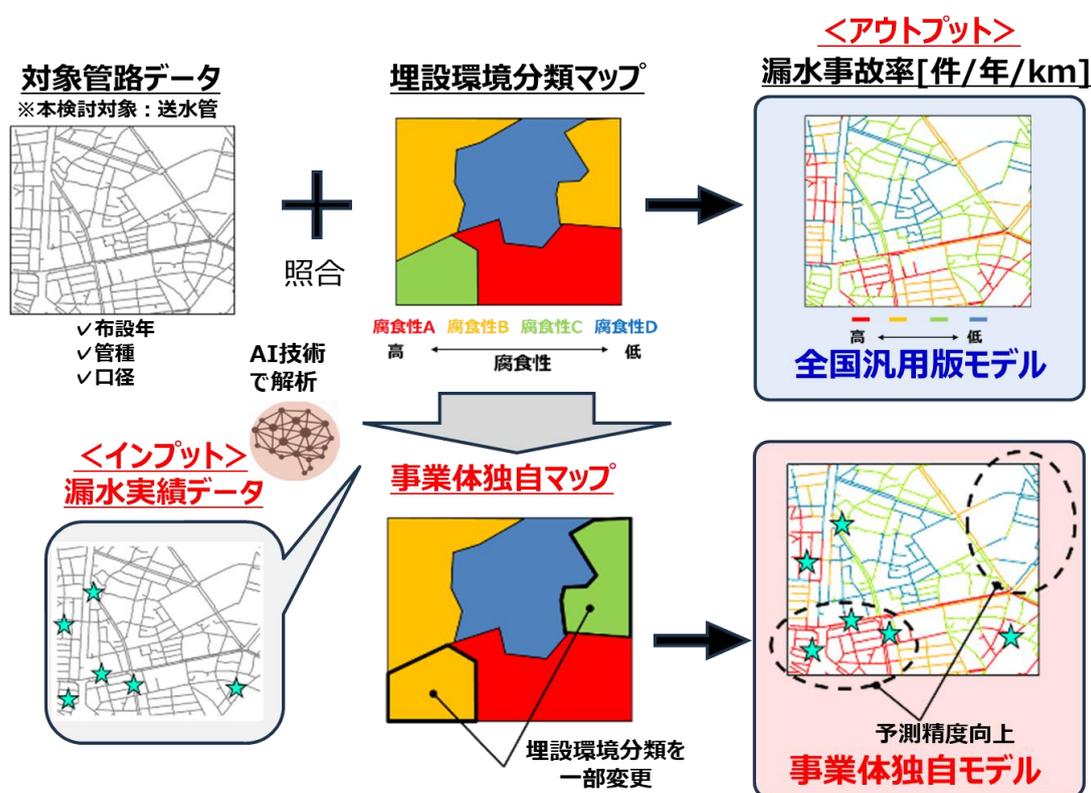


図-1 事業者独自モデルの構築イメージ

## 2.2 学習データの選別条件とケース設定

「事業体独自モデル」を構築するために収集した漏水実績データは、記録方法や精度にばらつきがあったため、実際に使用できる情報を選別する必要があった。しかし、選別条件を厳しくすると学習データが減少し、逆に学習データ数を確保しようとするとも情報の精度が低下するというトレードオフの関係がある。採用する漏水実績データ（学習データ数）が診断結果に与える影響を比較するため、表-2 に示す 2 つのケースを設定した。

まず、全データから、地震による漏水と、弁類や他工事に起因する漏水を除外し、150 件に絞る段階までは両ケース共通とした。

ケース①は、情報の精度を優先するケースであり、漏水実績の記録時と現在における管路属性（口径、管種）が完全に照合でき、かつ詳細な状況まで記録されているデータに限定し、さらに直近 20 年以内に発生した漏水のみを採用した。結果として 16 件のデータを学習データとして採用した。

ケース②は、学習データ数の確保を優先するケースであり、漏水事故記録時と現在の管路の属性が一部照合できないデータや、漏水原因・具体位置等の詳細が不明なデータも許容し、20 年以上前のデータも対象に含めた。結果として 51 件のデータを学習データとして採用した。

なお、本検証の対象は用水供給事業であり、診断対象は送水管のみである。

表-2 学習データの選別条件とケース設定

#	ケース① ＜情報の精度を優先＞≒理想的選定条件		ケース② ＜データの数を優先＞	
	選別条件	漏水件数 【件】	選別条件	漏水件数 【件】
1	事業体が保持する 全事故履歴	414	事業体が保持する 全事故履歴	414
2	#1のうち、地震時の事故を除外	305	#1のうち、地震時の事故を除外	305
3	#2のうち、弁類や他工事を除外	150	#2のうち、弁類や他工事を除外	150 <small>ここまでは同じ</small>
4	#3のうち、事故位置の管路と 管種・口径が <b>完全に一致</b>	66	#3のうち、事故位置の管路と 管種・口径が完全に一致（66件） + <b>具体的な漏水原因や発生位置の詳細が不明なものも採用（23件）</b>	89
5	#4のうち、 水管橋や更新済み管路を除外	34	#4のうち、 水管橋や更新済み管路を除外	54
6	#5のうち、 <b>2005年</b> から2024年に発生	<b>16</b>	#5のうち、 <b>1980年</b> から2024年に発生	<b>51</b>
<b>管種・口径が完全一致</b>				
○		○		
<b>具体的な漏水要因が明らかな</b>				
○		△		
<b>発生位置の詳細が明らかな</b>				
○		△		
<b>発生年度</b>				
<b>直近20年のみ</b>			<b>すべて含める</b>	

### 3. 診断結果の比較

AI 老朽度診断の結果は、管路更新を実施しなかった場合の 10 年後、20 年後、30 年後及び 40 年後における管路ごとの漏水事故率 [件/年/km] として示される。

診断結果の精度検証の手法としては図-2 に示すとおり、漏水事故率が高いと予測された管路から更新すると仮定し、今回老朽化が要因として整理された最大の 51 件の漏水実績箇所が管路更新率 [%] (=漏水事故率の高い管路順の累積延長 (km) / 診断対象管路全延長 (km)) のどの時点で出現 (的中) したかによって予測精度の比較を行った。更新率の低い段階で出現した漏水実績件数が多いモデルほど、予測精度が高いモデルであると評価した。



図-2 診断結果の精度検証のイメージ

図-3 に示す現状の漏水事故率を比較した場合は、ケース①、ケース②ともに経年順に更新した場合と大きな差が見られない。これは、管路はある程度経年化した時点で急激に漏水リスクが高まるためであり、短期的な計画においては既に老朽化した管路を更新対象としても大きな問題はないともいえる。

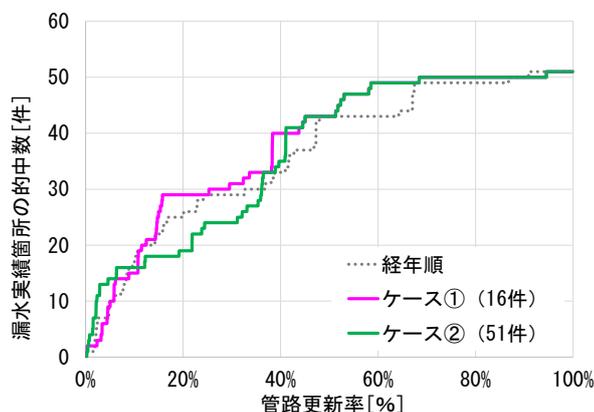


図-3 予測精度の比較 (現状の事故率)

一方、図-4 に示す 40 年後の漏水事故率を比較した場合では、特に更新率 30%以降の範囲でケース①、ケース②は経年順で更新した場合よりも早く漏水実績を的中しており、経年変化以外の漏水要因の影響が大きくなったものと考えられる。40 年後は、更新率 30~40%の範囲の管路が更新対象となるため（更新率 1.0%/年程度と想定）、その範囲においては漏水リスクの高い管路を更新対象として選定することができる。

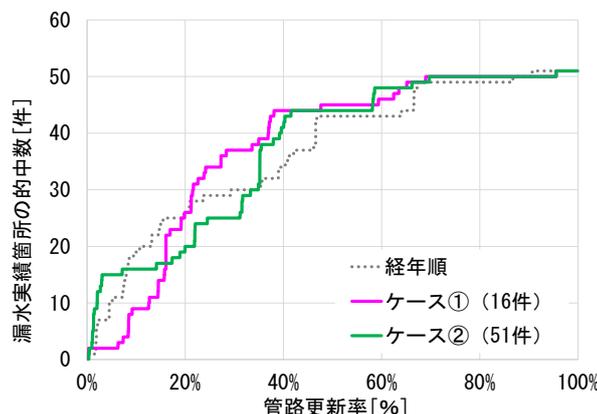


図-4 予測精度の比較 (40 年後の事故率)

#### 4. 考察

学習データの多いケース②は、将来の漏水事故率になるほど予測精度は向上したものの、総じてケース①よりも低い結果となった。今回の検証では、学習データが少なくとも確度の高い漏水実績を採用した方が優位な結果となった。この要因としては、対象管路が送水管であったことから、路線単位で布設年度が近く、同一管種で構成され、埋設環境にも大きな差がないなど、漏水実績に含まれる情報が類似しており、不確定な要素を学習させる必要性が少なかったと推察される。配水支管のように診断対象に面的な広がりがあり、また、様々な属性を持つ場合は、異なる結果が出る可能性も考えられる。

#### 5. おわりに

本稿では、学習データ数とその情報の確かさが予測精度に与える影響を示し、両者のバランスは対象とする管路によって異なることを示唆した。

AI 技術を用いた管路老朽度診断は、管路の最適な更新時期を検討するための有効なツールとなり得る期待は大きいですが、学習データの精度が予測精度に直結することから、学習データの精度向上が大きな課題の一つである。

同技術の活用を検討中の水道事業者のみならず、既に経験済みの水道事業者においても、本考察が管路更新計画の最適化に向けた一助となれば幸いである。

#### 【参考文献】

- 1) 川勝智、奥村勇太、船橋五郎、滝沢智：ダクタイトイル鉄管及び铸铁管の高精度な老朽度評価法の開発、水道協会雑誌第 91 巻 第 9 号 (第 1056 号)、pp.13-25 (2021)