

ニューラルネットワークを利用した トンネル崩壊規模推定に影響する要因分析

Affecting factor analysis of tunnel collapse magnitude using AI method

徐 景源¹⁾, 土門 剛²⁾, 鈴木 健之³⁾, 西村 和夫⁴⁾

Kyoungwon SEO, Tsuyoshi DOMON, Takeyuki SUZUKI and Kazuo NISHIMURA

Tunnel collapses due to various reasons according to the state of ground and excavation conditions and condition of support. It is very difficult to predict and evaluate them and prepare the strengthening in advance.

This study deals with development of the prediction system of tunnel collapse magnitude and analysis of the causes affecting the magnitude of the collapse.

Based on the analysis of data in this study, the main cause of collapse magnitude, which is the output node, is topography around the tunnel.

Key Words : tunnel collapse, neural network, inference

1. はじめに

既存の資料や情報に基づいてトンネルの安定性を事前に評価できれば、経済的な施工や適切な補助工法の選定などに大変有益である。安定性の評価は、掘削中あるいは掘削後の地表面沈下量や内空変位量などを考慮する場合が一般的であるが、本研究では、ニューラルネットワークによる安定性評価方法に着目し、ニューラルネットワークを用いた崩壊規模の推定手法やその前提となるニューラルネットワークの効率的な構築方法について論じた。

掘削時のトンネル安定性は、地質条件や支保の適合性あるいは補助工法の適合性などの様々な要因によって複雑な影響を受けるため、理論解の適用などの決定論的方法では安定性を事前に評価することが非常に難しい。たとえば、掘削前に崩壊危険性がどの程度あるかという問題一つをとっても、それを推定することは現状では困難であると考えられる。

近年、トンネル安定性などの事前評価を試みる手段として様々なAI(Artificial Intelligence)手法が適用されるようになっている。特に、ニューラルネットワークを利用した研究では、トンネル掘削による地表面沈下量の推定や、トンネル安定性の評価、支保パターンの選定、内空変位量予測などが試みられている¹⁾。しかし、ニューラルネットワークの構築においては良質かつ大量の学習データを必要とされるものの、実際のトンネルではこのようなデータを収集することは容易でない。したがって本研究では、学習データが少ない場合における最適な学習方法を新たに開拓することを目的とした。

¹⁾ 学生会員 東京都立大学大学院 工学研究科 土木工学専攻 博士課程1年

²⁾ 正会員 東京都立大学大学院 工学研究科 助手

³⁾ 学生会員 東京都立大学大学院 工学研究科 土木工学専攻 博士課程3年

⁴⁾ 正会員 東京都立大学大学院 工学研究科 教授

に提案するとともに、本研究の学習データとして使用したトンネル崩壊現場の崩壊規模に及ぼす要因について分析した。なお、本研究ではトンネル崩壊は地質・地形条件にのみ影響し、補助工法や発破などの施工の影響は考慮していない。

2. ニューラルネットワークと崩壊現場の資料について

2.1 ニューラルネットワークの概要

近年、地盤工学分野において適用されているAI手法には、Fuzzy、ニューラルネットワーク、Neuro-fuzzy、Genetic algorithm、エキスパートシステムなどがあるが、本研究では未知の現象を推論する能力に秀でたニューラルネットワークを利用するこにする。ニューラルネットワークは、人間の神経伝達過程を単純化して、これを数学的にモデル化したもので、外部からの入力データを入力層のニューロンが受け、さらに下流の複雑に絡み合ったニューロンリンクを通過しながら最終的に出力データを得るものである。この際、ニューロン同士の連結強度を調節する一種の学習過程を通じて自己組織化される。ここで学習とは、出力値（目標変数値）を最も精度よく予測する最適なリンクの強度（重み）を探していく過程とみなすことができる。

ニューラルネットワークには様々な種類があるが、本研究で使用される誤差逆伝搬法は、多層ペーセプトロンで構成されており、入力層、中間層（あるいは隠れ層）、出力層に大別される（図-1）。入力層に入った外部データは、通過したシナップス結合荷重（重み）を乗じて各層で加算される。出力層では推定値と実測値の誤差をデルタ則によって学習させる。

このようなニューラルネットワークの長所は、1) 非線形現象を分析することができる、2) 分析時間が短い、3) パターン認識や予測などに効果的である、が挙げられる。一方、短所は、1) 既存の良質かつ大量のデータの収集・分類が必要である、2) 新しいデータが追加されると、再度学習し直さなければならぬ、などがある。

2.2 トンネル崩壊資料の分析

表-1に、本研究で調査・分析した韓国

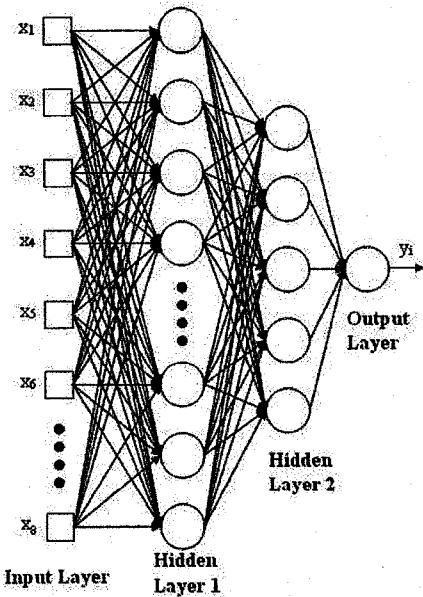


図-1 ニューラルネットワークの構造例

表-1 崩壊現場の地山状態と現場数

地山の状態	現場数 (%)
不連続面の数	massive (5%), one set (23%), two set (31%), three set (10%), random (19%), crushed/earthlike (12%)
地下水の状況	no water (21%), minor water (18%), minor flow (33%), flow (19%), large water (9%)
崩壊切羽と隣接区間のRQD	0-25% (29%), 25-50 (24%), 50-75 (16%), 75-90 (20%), 90-100% (11%)
岩石種類	深性岩類 (40%), 堆積岩類 (2%), 片岩類 (14%), 片摩岩類 (12%), その他変性岩類 (32%)
トンネルの深度	<15m (25%), 15-30m (60%), 30-45m (5%), 45m < (10%)
切羽における岩盤	風化土層 (5%), 風化岩層 (40%), 軟岩層 (30%), 普通岩層以上 (25%)
崩壊規模	<50m³ (50%), 51-150m³ (10%), 151-300m³ (20%), 301-500m³ (0%), 501m³ < (30%)

の崩壊現場の地山状態とその割合について示した。収集された崩壊現場は 20 箇所であり、そのうち鉄道トンネルが 2 箇所、道路トンネル 4 箇所、地下鉄 14 箇所である。大部分の崩壊は土被り 3 D 以下の低土被り区間で発生している。また、切羽の岩盤は、風化岩層 (40%)、軟岩層 (30%) であるが、天端直上部には被覆厚さの非常に薄い岩盤が存在し、地表面からトンネル掘削深度のほとんどに風化した岩あるいは土が厚くて分布している。すなわち、地山のせん断強度を期待できない状況にあった²⁾。

3. ニューラルネットワークを利用した崩壊規模の推定

3.1 新たな学習方法の提案

本研究で用いられる弾力性誤差逆伝搬法 (Resilient backpropagation: RPROP) は Riedmiller により提案された手法として学習の一般化と学習効率を向上させたアルゴリズムである。RPROP アルゴリズムの特徴は各層結合強度の大きさに過敏な影響を排除して、より安定的な推論ができる点である。また、本研究で用いる感度分析には Yang³⁾ や Kim¹⁾ が提案した手法を用い、入力層（トンネル崩壊に影響する要因）に対して出力層（崩壊規模）の相対的な変化の程度を示すこととする。

まず、ニューラルネットワークを構築するには、学習データが必要である。本研究は表-1 に示した韓国の 20 箇所のトンネル崩壊事例に基づいて、入力層として地質・地形条件を、出力層は崩壊規模を考慮することとした。ニューラルネットワークの効率的な学習には、多くのデータが必要とされるが、収集した資料が少ない今回のケースでは、学習済みの出力層として使用される崩壊規模の格差は大きくなってしまう。したがって、次のような二つの学習方法を提案し、この問題に対処することとした。第一に、データの量に合わせて入力層の個数を削減する方法、第二に、出力層として使用される崩壊規模の差異を減らす方法である。

3.2 ニューラルネットワークの構築と学習

(1) 入力層と出力層の設定

ニューラルネットワークの構造は、入力層や中間層および出力層で構成され、各層の個数が多くなるほどより連結度の高い構造が要求される。その際、得られた学習に比べてニューラルネットワークの構造が複雑になると、学習の一般化を失い、未学習資料については信頼性の乏しい推論がなされてしまう。したがって、本研究では与えられた学習に応じて入力層を 14 個および 4 個の 2 種類で設定し、出力層は 3 段階に設定した（表-2）。

14 個の入力層の設定は収集した資料に基づいてトンネル崩壊に影響を及ぼす地形的、地質学的などの条件を 14 個の要因として分類した。また、4 個の入力層の設定は 14 個の入力層に基づいてトンネル崩壊に最も影響を及ぼす要因を新たな層として選定した。ここで、深度関連層はトンネル上部から地表に至るまで多くの層から構成されることを考慮して、式(1)により定義した。

$$\sqrt[3]{\sum_{i=1}^n h_{s_i} \cdot \gamma_{s_i} + \sum_{j=1}^m h_{r_j} \cdot \gamma_{r_j}} \quad (1)$$

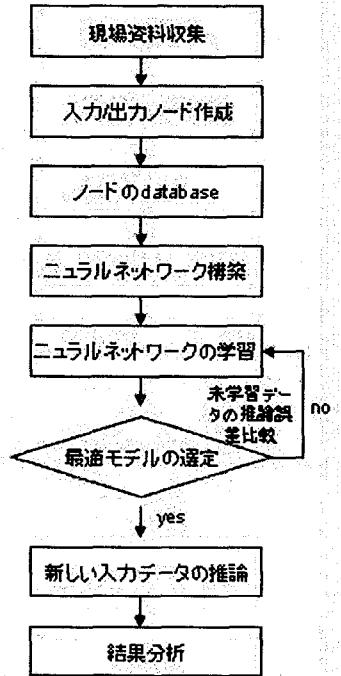


図-2 ニューラルネットワーク構築のフロー図

ここで、 h および γ はそれぞれ各地層の層厚および単位体積重量を、添字の s および r は、それぞれ軟岩層（風化岩層も含む）および硬岩層を示している。

14個の入力層のうち不連続面に関する項目、すなわち介在物、方向性、間隔、幅などを一つの層として扱えるようにQシステムを用いた。なお、RQDとSRFは1と仮定し、不連続面の各項目を点数化するため式(2)のように新たな関係式を定義した。RQD層は、崩壊地点あるいは崩壊地点に近接した区間で得られた値を用い、地形関連層はトンネル路線が位置している地形的特徴を有する層とした。

$$Q_{discontinuity} = \frac{1}{J_n} \times \frac{J_r}{J_a} \times \frac{J_w}{1} \times 100 \quad (2)$$

一方、出力層として使用した崩壊規模は5~900m³と範囲が広範であるため、学習資料のすべての事例ができる限り一定の感度を保てるように出力層の範囲をroot関数で段階的に削減を図った（以下ではM1, M2, M3で表示）。

表-2は、学習に使用された14個および4個の入力層を示している。入力層の内容を決めるには、まず、求めたい結果（本研究ではトンネル崩壊規模）

を設定した後、結果に影響を及ぼす要因について次のように事前分析をおこなう。本研究の対象地山の特徴は、トンネル上部には風化が激しい層からなる一方、トンネル断面は部分的に岩盤で構成されているため、崩壊の特徴や地形・地質などの特徴を考慮し、同表のような項目を設定した。もし、収集した資料が土砂地山であれば、粘着力、内部摩擦角、先行補強の種類、土被り等が入力層に加えられると考えられる。

（2）ニューラルネットワークの学習

表-3は、本研究のニューラルネットワークモデルの入力および出力層の構成を示している。ニューラルネットワークの学習は20箇所の崩壊事例中の19事例を学習データとして使用し、残る1箇所の事例を未学習データの誤差特性を検討する資料として使用した。学習モデルは前述の通り入力層を14個および4個使用し、出力層をM1, M2およびM3とした。本研究の目的は、収集資料が少なくかつ出力層（崩壊規模）の差が大きな場合に対しても有効な学習手法を提案することにあるため、学習に必要な各種条件を固定して、各々モデルを50,000回まで繰り返し学習させた。このとき、学習途中に10回にわたって学習データの再推論誤差と未学習データの推論誤差を分析した。

（3）学習結果

ニューラルネットワークを利用した多くの研究では、最適学習を学習に使用したデータの再推論誤差率が少なくなるようにモデル化することが多い。しかしながら、ニューラルネットワークの最終目的は新たな資料が提供された場合、出力値を適切に推論することであるから、本研究では再推論誤差率が少なくなるよりも未学習データの推

表-2 学習に使用された入力層とその種類

入力層	
14個層	深度、大きさ、RQD、地下水の状態、不連続面の数、岩盤風化度、不連続面の方向性、岩石種類、地形要素1、地形要素2、破碎帶の特徴、断層帶の特徴、変成鉱物の有無、岩盤風化度の違い
4個層	深度関連、RQD、地形関連、 $Q_{discontinuity}$

表-3 ニューラルネットワークの学習モデル

入力層	出力層	モデル名	学習データの再推論誤差率、未学習データの推論誤差率
14個	M1	14-M1	各々モデルは50,000回に達するまで、10回にわたり誤差率分析する
	M2	14-M2	
	M3	14-M3	
4個	M1	4-M1	
	M2	4-M2	
	M3	4-M3	

論誤差率が少なくなるようなモデルを最適学習モデルと位置づけた。

図-3に、ニューラルネットワークの入力層を14個および4個とした場合に対する出力層(M1, M2, M3)の学習後の未学習データの推論誤差率について示した。14個の入力層を持つモデルでは、出力層の範囲をM1, M2, M3の順に段階的に削減した結果、この順に誤差率が減少している様子がわかる。また、4個の入力層を持つモデルの場合は誤差率がM1からM2で急激に減少している傾向がみられる。すなわち、収集した資料が少ない場合には、本研究で提案した二つの学習方法を利用してニューラルネットワークを構築すれば、未学習データの推論をより効果的であると言える。

3.3 トンネル崩壊に影響を与える要因

トンネル崩壊規模は多くの要因によって影響を受ける。特に、地山とトンネル路線との幾何的条件や崩壊発生時の初期対策などによって崩壊規模は大きく異なるが、本研究では、掘削前の地形条件および地質条件に基づく崩壊規模予測手法の適用性を検討した。

感度係数は、入力層に対する出力層の微分値を意味し、地山条件による崩壊規模の程度を表現することができる。表-3の学習モデル中で最適なモデルであった4-M3モデルの感度を示すと図-4のようになる。ここで、縦軸の感度係数の絶対値は入力層に対する出力層の相対的な変化の度合いを示している。すなわち、出力値(トンネル崩壊規模)に対して入力層である深度、RQD、地形層、 $Q_{discontinuity}$ 層の各々の影響の程度を示すものと解釈できる。したがって、本研究で使用された資料の場合は、トンネル路線の地形に関する影響をもっとも大きく受けていることが明らかとなった。崩壊を引き起こした地形では、そのほとんどが過去に大規模な変成作用を受けて破碎帯が形成され、それが広範囲に分布していたためトンネル崩壊規模が大きくなつたと考えられる。その他同図によれば、トンネル深度、不連続面、RQDの順に崩壊規模に影響を与えることがわかる。このような結果は対象とする地山の種類によって結果が異なるものと思われる。つまり、土砂地山のトンネルでは崩壊に影響を及ぼす原因が岩盤トンネルとは異なり、入力層を新たに構成し直さなければならない。適切な入力層を選定することができれば、本研究で提案された手法を適用して定量的な推定ができると考えられる。

4. おわりに

本研究では、トンネル崩壊のように、現場では得にくい資料に基づいてニューラルネットワークを使用する場合の最適学習手法を提案した。トンネル崩壊に影響を及ぼす要因について分析した結果、以下のような知見が得られ

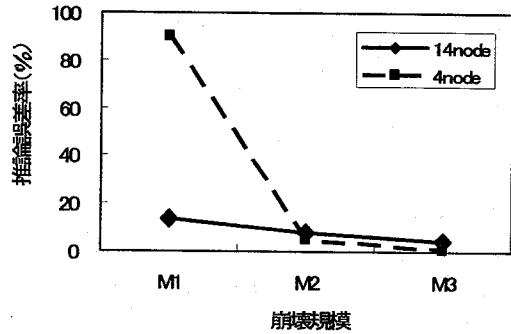


図-3 未学習データの推論誤差率

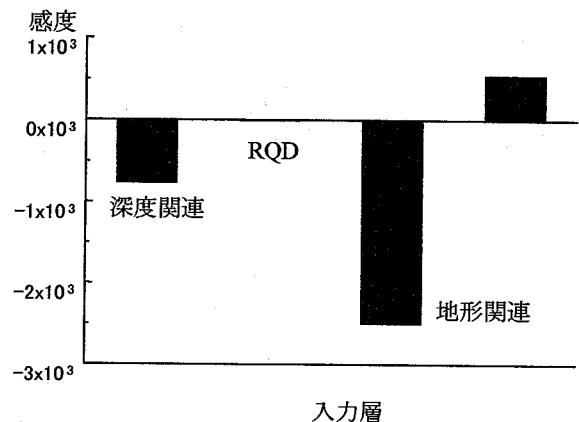


図-4 崩壊規模に影響を与える要因の感度分析

た。

- ① トンネルの安定性を評価する手法は多いが、本研究ではニューラルネットワークを用いて掘削前に既往の崩壊事例の学習データから、新しく掘削する現場の地山条件を基礎データとするニューラルネットワークによる崩壊規模予測システムを開発した。
- ② 学習資料が少ない場合には、ニューラルネットワーク構成の簡便化を図ることにより、より効率的に未学習資料の推論ができる。
- ③ トンネル崩壊規模は多くの要因によって影響を受けるが、本研究で扱ったケースではトンネル路線の地形的条件にもっとも大きな影響を受ける。

本研究では主に岩盤トンネルを対象に、崩壊規模に影響を及ぼす要因として地質条件や地形条件のみを考慮したが、今後、補助工法や支保パターンなどのデータを追加し、良質かつ大量の資料を学習資料として使用すれば、トンネル掘削による崩壊危険性を評価する一手法としてさらに適用範囲が広がるものと考えている。

参考文献

- 1) たとえば、C.Y.Kim, G.J.Bae, S.W.Hong, C.H.Park, H.K.Moon, H.S.Shin : Neural network based prediction of ground surface settlements due to tunneling, Computers and Geotechnics, vol.28, pp.517-547, 2001
- 2) Sang-Joon Ma, Kyoung-Won Seo : Application of Tunnel Information Management System and Tunnel Collapse Inference System in Tunnel, ISRM EuroRock2000, pp.512-518, 2000
- 3) Y.Yang and Q.Zhang : A Hierarchical Analysis for Rock Engineering Using Artificial Neural Networks : Rock Mechanics Rock Engineering, No.30, No.4, pp.207-222, 1997