

ニューラルネットワークを用いた堆積岩および火成岩に分類した山岳トンネルにおける地山評価結果

増田 千胤¹・北岡 貴文^{1*}・長谷川 信介²・大津 宏康¹

¹京都大学大学院 工学研究科都市社会工学専攻 (〒615-8530 京都市西京区京都大学桂)

²応用地質株式会社 メンテナンス事業部 (〒331-8688 埼玉県さいたま市北区土呂町2-61-5)

*E-mail: kitaoka.takafumi.6e@kyoto-u.ac.jp

山岳トンネルの建設プロジェクトでは、事前調査における地山等級と実際の地山等級の乖離により、しばしば施工時に建設コストが大幅に増加する事態が生じている。このため、事前調査における地山等級の予測精度の向上が求められている。筆者らは、地山等級の予測精度の向上を目的にニューラルネットワークによる地山等級の予測に関する研究を行っている。本研究ではまず前処理として標準偏差で正規化したデータをニューラルネットワークに入力し、正規化が結果に及ぼす影響を検討した。さらに、堆積岩と火成岩では地山特性が異なることから、物性値の他に岩種（堆積岩・火成岩）の情報もニューラルネットワークに学習させた。その結果、岩種を考慮することが予測精度を向上させる上で重要であることを示した。

Key Words : mountain tunnel, artificial neural network, geo risk, normalization, rock type

1. はじめに

山岳トンネルの建設プロジェクトでは、しばしば事前調査・設計時に想定された地山等級と実際の地山等級の乖離により施工時に建設コストが増大する事態が生じている。このため事前調査・設計時の地山評価の精度向上が求められている。このようなコスト増大が生じる背景として、山岳トンネルが土被りの大きい細長い線状構造物であり、予算や時間の制約、地質調査の技術的境界により事前の地質調査で得られるデータ量が少ないことが挙げられる。

施工段階では切羽において切羽評価点法^{2,3)}による地山評価が行われるが、事前調査では切羽評価点の評価項目に該当する情報が得られないため、設計時の地山評価と実際の施工時の支保工の間に乖離が生じる要因となっている。事前調査においては物理探査およびボーリング調査がトンネルルート沿いの物性値を定量的に得られる手法であり、限られた物性値のデータを有効に活用し精度の高い地山評価を行うことが求められている。

従来の地山評価においては事前調査で得られた物性値のデータから地山分類表⁴⁾に基づいて地山等級が決定され、設計時には地山等級に対応する標準支保パターンを適用することが一般的である。しかしながら、各物性値と地

山等級は複雑に関連するため、各物性値の相関を単純な相関式で与えることでは精度の高い地山評価を行うことは困難である。そこで著者らは各指標と地山等級の関係について定式化が不要なニューラルネットワーク（Artificial Neural Network；ANN、以後ANNと称す）を利用することとした。ANNは学習機能を通じて入力データと出力データを関連づけられることが特徴⁵⁾であり、物理探査で得られる物性値と地山等級の関係性を高い精度で関連付けられる可能性がある。

山岳トンネルの地山評価に関するANNの適用性について、長谷川ら⁶⁾は2本のトンネルデータを用いてANNによる地山等級の予測を行い、地山評価の精度向上のためには多様な地山特性を有するトンネルデータを蓄積することが重要であると指摘している。また土谷ら⁷⁾は13本のトンネルデータを用いてANNによる地山評価の精度向上を試み、ANNに単一の物性値ではなく弾性波速度、比抵抗、土被りの3種類のデータを説明変数として学習させた場合に地山評価の精度が向上することを示した。

一般的にANNを含む機械学習では特徴量間のオーダーの違いが解析結果に与える影響を軽減するため、使用するデータに前処理を施す必要がある⁸⁾が、既往の研究では前処理の手法に関する検討は行われてこなかった。そこで本研究では前処理として、既往の研究で行われて



いる対数変換を施したデータと、標準偏差を用いて正規化を施したデータをそれぞれANNに入力し、前処理の手法がANNの出力結果に及ぼす影響を検討した。さらに、堆積岩と火成岩では地山特性が異なることを想定し、岩種ごとに分類したデータをANNに入力し、岩種の情報が出力結果に与える影響について考察を加えた。ANNのモデルでは定式化する作業がなく、出力結果は相関的に求められるため、モデルの特徴を定性的に把握する必要がある。本研究では出力結果を弾性波速度と比抵抗、土被りの3軸で示し、地質学的な視点から考察を加えANNの出力結果の特性を把握することを試みた。

2. 解析の概要

(1) トンネルデータ

本研究では既往の研究⁷⁾と同様に13本のトンネルデータを使用する。用いたデータの種類の、トンネル掘削位置における弾性波速度 (km/s) , 比抵抗 ($\Omega\cdot m$) , 土被り (m) , 岩種および切羽観察により判定された地山等級 (B→C1→C2→Dの順に不良地山) である。これまでの研究では説明変数として物性値のみを考慮していたが、本研究では岩種も考慮し高精度で地山評価を行うことを試みた。図-1、図-2に使用したデータの特性を記す。

図-1が示すように全データの内訳は堆積岩が506個、火成岩が515個、その他・岩種不明が37個である。また図-2が示すように堆積岩については不良地山側に多くのデータが存在する一方で、火成岩については良好な地山



側に多くのデータが存在する。したがって、岩種をANNへの入力情報に加えることが適切であると考えられる。

(2) ANNの概要

ANNは人間の脳の動きをコンピュータに模倣させる目的で生まれた情報処理手法である⁹⁾。ANNは複雑な非線形処理を得意とし、学習機能を用いることで説明変数と目的変数の関係を定式化する必要がないという特徴を持つ。ANNは一般的に入力層、中間層、出力層で構成される。入力層には説明変数が入力され出力層からは目的変数が出力される。中間層は両者を関係づける役割を担っている。中間層の層数および各中間層のニューロン数に関して制約は無く、任意に設定することができる。

本研究で用いるANNモデルは入力層、ニューロン数が500の中間層が6層、出力層からなる。入力層には説明変数としてトンネル掘削位置における物性値を入力し、中間層では活性化関数としてランブ関数 (ReLU) を使用した。出力層では4つの地山等級 (B,C1,C2,D) を確率分布として出力するためソフトマックス関数 (Softmax) を使用し、最も確率が高く出力された地山等級をANNが出力した地山等級とした。使用したANNのソフトウェアライブラリは、Python言語のTensorFlow¹⁰⁾である。

(3) ANNモデルの決定

本検討では、既往の研究で使用されているANNモデルを参考に、ANNの学習を開始する前に予め設定しておく必要があるパラメータであるハイパーパラメータを調整し、以降の解析で用いるANNモデルの構築を行う。高い精度を与えるANNモデルの構築にあたりハイパーパラメータを適切な値とすることが重要であるが、その調整は一般的に試行錯誤的に行われる⁹⁾。ここでANNの精度とは、教師データによる学習が終了したANNに対し、テストデータを入力したときにANNが出力する地山等級（予測結果）と切羽観察で判定された地山等級（正解）の一致率を表す。本検討ではハイパーパラメータである中間層のニューロン数と層数に関してニューロン数、中間層の層数の順で最適値を探索した。またANNモデルを評価する手法としてK-分割交差検証を実施した。K-分割交差検証では全データをK個のグループに分割し、1つ目のグループをテストデータ、その他のグループを教師データとしてモデルの精度を算出する。次に、2つ目のグループをテストデータ、その他のグループを教師データとしてモデルの精度を算出する。このような操作をK回繰り返し、各回で算出された精度の平均値をモデルの精度とする。本研究では全データを10個に分割 (K=10) し、各ハイパーパラメータの値に対してモデルの精度を算出した¹¹⁾。また本検討では入力データの値の範囲を揃えるため既往の研究⁷⁾と同様に前処理

表-1 ハイパーパラメータの最適化（ニューロン数）

入力データ	出力データ	中間層数	ニューロン数	モデル精度 (%)
弾性波速度 比抵抗 土被り	地山等級 (B,C1,C2,D)	6	5	57.5
			15	62.3
			30	64.2
			50	68.3
			100	72.4
			500	74.4
			1000	72.4

表-2 ハイパーパラメータの最適化（中間層数）

入力データ	出力データ	中間層数	ニューロン数	モデル精度 (%)
弾性波速度 比抵抗 土被り	地山等級 (B,C1,C2,D)	3	500	71.4
		6		74.4
		8		71.6
		10		70.7

として対数変換を施したデータをANNに入力した。

本検討の結果を表-1、表-2に示す。まずニューロン数に関して表-1よりニューロン数が500のとき最も精度が高くなることが分かる。また中間層の層数については表-2より6層のとき最も精度が高くなることが分かる。したがって以降の検討ではニューロン数が500、中間層の層数が6層のモデルを使用した。

3. 入力データの前処理に関する検討

ANNによる解析では一般的に特徴量間のオーダーの違いが解析に与える影響を軽減する目的で、数値を一定の範囲内に揃える前処理を施したデータを使用する。対数変換は既往の研究において用いられている前処理の手法である。機械学習で一般的に用いられる前処理の手法としては、標準偏差を用いた正規化と最小値および最大値を用いた正規化の2種類存在する。しかしながら、後者の手法ではデータの最小値および最大値を用いるため、使用するデータに外れ値が存在した場合に外れ値が正規化後のデータに大きく影響を与えるという特徴がある。このため本検討では、13トンネルのデータの物性値に対し前処理として、標準偏差を用いた正規化を施した場合と、対数変換を施した場合のANNの出力結果を比較し前処理の手法の違いが結果に与える影響を考察した。

(1) 対数変換の場合

本検討では、3種類の物性値（弾性波速度、比抵抗、土被り）に対し前処理として物性値ごとに対数変換を施しANNに入力した。表-3にANNの構築条件を示す。本検討では教師データに全トンネルデータ（1058個）を使

表-3 ANN構築条件

入力層	弾性波速度 比抵抗 土被り
中間層	層数：6層 ニューロン数：500
出力層	地山等級 (B,C1,C2,D)
学習回数	10000回
教師データ	全トンネル
テストデータ	表-4

表-4 テストデータ (1)

テストデータ	入力値 (最小値, 最大値, 刻み幅)
弾性波速度	(0.1, 6.0, 0.1) (km/s)
比抵抗	(100, 6,000, 100) (Ω -m)
土被り	(50, 400, 10) (m)




図-3 ANN出力結果（対数変換）




図-4 ANN出力結果（標準偏差を用いた正規化）

用しテストデータは表-4に示すデータを使用した。これにより教師データに含まれないデータに対してANNが与える地山等級の分布を把握することができる。図-3に結果を示す。3軸として縦軸に土被りを示すことで、深度方向のANNの特性についても考察を加えた。図-3より弾性波速度が2.0 (km/s) 以下の領域では比抵抗の大きさに関係なくD地山が卓越することがわかる。また土被りの増加と共に良地山側へ移行する傾向がみられる。

(2) 標準偏差を用いた正規化

本検討では3種類の物性値に対し前処理として標準偏差による正規化を施しANNに入力した。まず教師データとして用いる全トンネルのデータに対して物性値ごと

に式(1)により正規化した。ここで x' は正規化された物性値、 x は物性値、 μ は物性値の平均、 σ は標準偏差で

$$x' = \frac{x - \mu}{\sigma} \quad (1)$$

ある。次に表-4に示すテストデータに対して教師データの平均値、標準偏差を用いて正規化を行った。以上により得られた正規化された教師データとテストデータを対数変換の場合と同様に表-3に示す構築条件のANNに入力した。図-4に結果を示す。図-4より土被りが200 (m) 以浅の領域では弾性波速度が増加すると良地山が増加する傾向がみられる。一方で、土被りが300 (m) 以深の領域では弾性波速度、比抵抗の値に関らず良地山と不良地山が混在する結果となった。

(3) 考察

まず学習が終了したANNに対し全トンネルデータをテストデータとして入力すると、前処理として対数変換を施した場合にはANNの出力結果と施工時の地山等級の一致率が88.8%、標準偏差を用いた正規化を施した場合には94.5%となり正規化の場合に高い一致率を示した。

つぎに前処理の手法の違いが出力結果に与える影響を考察する。比抵抗が2000 (Ω -m) 未満の領域では両者の結果は類似していると考えられる。具体的には両者共に土被りが100 (m) および200 (m) において弾性波速度が3 (km/s) 以下でD地山が卓越し弾性波速度の増加と共に良好な地山へ移行する傾向がみられる。また土被りが300 (m) および400 (m) において両者の結果を比較すると、弾性波速度が1 (km/s) 未満におけるD地山の分布領域は異なるもののC2地山およびD地山を中心とした不良地山が卓越することが表現されている。また弾性波速度が3~4 (km/s) において両者共にD地山が分布することが表現されている。また土被りが増加するにしたがって良地山側に移行する傾向がみられ、土被りは弾性波速度と同様に地山の硬さの影響を受けていると考えられる。以上より地山評価の際には弾性波速度だけではなく比抵抗と土被りを含めた3種類の物性値を考慮することが重要であると考えられる。

一方で比抵抗が2000 (Ω -m) 以上の領域について、図-3、図-4が示すように両者の結果は大きく異なっている。この要因の一つとして教師データの分布の偏りが考えられる。本検討では教師データに含まれないデータに対するANNによる出力を把握する目的で表-4に示されるデータをテストデータとして入力した。このテストデータは教師データの物性値の最小値および最大値をもとに作成したものである。しかしながら、図-5に示すように教師データは一様に分布しておらず、大部分のデータにおいて2000 (Ω -m) 未満となっている。このことから教師




図-5 使用データにおける比抵抗のヒストグラム

データが十分に存在しない領域については前処理の手法の違いがANNの出力結果に影響を与えられられる。また、比抵抗が上昇すると一般的に岩石の間隙率、風化の程度が小さくなる¹²⁾ことから、比抵抗が2000 (Ω -m) 以上の領域では2000 (Ω -m) 以下の領域と比較して良好な地山が分布すると考えられ、これは図-3の結果と一致する。したがって前処理として対数変換を施した場合には教師データが少ない領域においても地質学的な情報を表現できると考えられる。一方で図-4では比抵抗が2000 (Ω -m) 以上、土被りが300 (m) および400 (m) かつ弾性波速度が3 (km/s) 以上の領域においてもD地山の分布がみられる。このことから前処理として標準偏差による正規化を施した場合には教師データが少ない領域において地質学的な情報を表現できない可能性がある。

本検討では前処理の手法の違いがANNの出力結果に及ぼす影響を考察した。その結果、前処理として標準偏差を用いた正規化を施した場合では、一致率が向上する一方、地質学的な情報を表現できない可能性がある。地山評価の精度向上にあたってはANNの出力結果と施工時の地山等級の一致率を向上させるのみならず、地質学的な要因を説明できることも重要である。以降の解析では、上記の検討を踏まえ（使用する入力データの特性を考慮）対数変換を前処理の手法として用いた。

4. 岩種（堆積岩・火成岩）ごとの地山評価

本検討では山岳トンネルが建設される地山には様々な地質状況が存在し、各地質状況における特性が存在すると考えられることから堆積岩、火成岩のデータについて、それぞれ前処理として対数変換を施しANNに入力した。

(1) 堆積岩の地山評価

堆積岩に分類されたデータを表-5のANNに入力した。テストデータは表-4に示すデータを使用した。図-6にANNの出力結果を示す。図-6に示すように弾性波速度が3.0 (km/s) 以下の領域でD地山が卓越することがみて

とれる．一方，弾性波速度が3.0 (km/s) 以上の領域ではD地山の領域が減少すると共に比抵抗および土被りの大きさに依存して地山等級が出力されており，土被りの増加と共に良好な地山が増加する傾向がみられる．

(2) 火成岩の地山評価

火成岩に分類されたデータには比抵抗が3500 ($\Omega\cdot m$) 以上のデータおよび土被りが300 (m) 以上のデータが存在しなかったため，テストデータとして表-6のデータを使用した．図-7にANNの出力結果を示す．弾性波速度が2.0 (km/s) 以下の領域ではD地山が卓越する一方，2.0 (km/s) 以上の領域では比抵抗の大きさに依存して地山等級が出力されている．また土被りの増加にしたがっ

表-5 ANN構築条件

入力層	弾性波速度 比抵抗 土被り	
中間層	層数：6層 ニューロン数：500	
出力層	地山等級 (B,C1,C2,D)	
学習回数	10000回	
教師データ	堆積岩	火成岩
テストデータ	表4	表-6

表-6 テストデータ (2)

テストデータ	入力値 (最小値, 最大値, 刻み幅)
弾性波速度	(0.1, 6.0, 0.1) (km/s)
比抵抗	(100, 3,500, 100) ($\Omega\cdot m$)
土被り	(50, 300, 10) (m)




図-6 ANN出力結果 (堆積岩)




図-7 ANN出力結果 (火成岩)

て良好な地山の領域が拡大する傾向がみられる．

(3) 結果と考察

まず，堆積岩の出力結果 (図-6) と火成岩の出力結果 (図-7) の大きな違いとして，土被りが浅い領域において火成岩の出力結果が堆積岩の出力結果と比較して良好地山側に偏っていることが挙げられる．岩種による地山評価の違いについて事前設計時の地山評価の観点から検討する．建設プロジェクトに大きな影響を与えるD地山に関して事前設計と施工時の地山等級の一致率を考えると，堆積岩では239個のD地山のデータのうち50%にあたる119個は事前設計時に予測されていた．また火成岩については95個のD地山のデータのうち48%にあたる46個は事前設計時に予測されていた．したがって本検討で使用したデータは火成岩が堆積岩と比べ良好な地山が多いものの，どちらかの岩種に特異なデータが存在していたのではなく，D地山を事前設計時に予測する難しさは岩種に関らず同等と考えられる．以上より堆積岩と火成岩における出力結果の違いは，火成岩のデータに良好な地山のデータが多く含まれていたという教師データの特徴をANNが反映したことが要因であると考えられる．

一方，両者の類似点は弾性波速度が小さい領域ではD地山が卓越するが弾性波速度が大きい領域では地山等級が比抵抗および土被りの影響を受けていると考えられることである．図-6および図-7より同じ弾性波速度であっても比抵抗の大きさにより複数の地山等級が分布することが分かる．また両岩種ともに土被りが増加するにしたがい地山等級が良好側へ移行する傾向がみられた．これは土被りの増加と共に上載圧が増加し切羽における岩盤の硬さが増大する為であると考えられる．また土被りの大きさは地層が形成されてからの期間に影響を受けると考えられ，土被りが小さく新しい地層は圧密，続成作用が進行しておらず軟らかい可能性がある¹²⁾．以上からANNの出力結果において土被りの増加と共に良好な地山の分布領域が拡大したと考えられる．本検討で得られた出力結果より地山等級は3種類の物性値から影響を受けていると考えられる．現状では破碎帯などの特異な地質を表現できていないが，今後物性値および岩種のデータの充実により表現できるようになる可能性がある．

またANNに教師データを入力し説明変数と目的変数を関連付けることを学習と呼ぶが，学習が十分に進行していれば，学習済みのANNに対して教師データを入力するとANNの出力結果と切羽観察で得られた地山等級は高い一致率を示すと考えられる．そこでANNの学習の進行状況を把握する目的で学習済みのANNに教師データを入力した．その結果，ANNの出力結果と施工時の地山等級の一致率は堆積岩で92.1%，火成岩で92.6%であり全トンネルデータを入力した場合の88.8%よりも多

少ではあるが高い一致率となった。したがって物性値に加えて岩種の情報をANNに学習させることは学習を効果的に進め、地山評価の精度を向上させる可能性がある。

5. 結論と今後の課題

本研究では、ANNに入力するデータに施す前処理の手法と入力データの性質がANNの出力結果に与える影響を考察した。以下に本研究で得られた知見を示す。

・前処理の手法について対数変換と標準偏差による正規化の2種類を比較した。その結果テストデータに教師データと同じデータを入力すると、標準偏差による正規化を施した場合にANNの出力結果と施工時の地山等級の一致率が高くなった。しかし標準偏差による正規化を行った場合には教師データが少ない領域に関して地質学的な情報を表現できなかった。使用するデータの特性に応じて、適切な前処理について検討する必要がある。

・学習済みのANNに教師データと同じデータをテストデータとして入力すると、ANN出力結果と施工時の地山等級の一致率は堆積岩の場合では92.1%、火成岩の場合では92.6%であり全トンネルを学習させた場合の88.8%と比較して高い結果となった。また岩種の情報を考慮した場合には前章の考察よりANNの出力結果に地質学的な情報も表現されていると考えられる。したがって物性値に加えて岩種の情報も考慮することで効果的にANNの学習を進めることができるようになる可能性がある。

本研究では岩種情報を考慮する際にトンネルデータを岩種毎にANNに入力したが、今後は岩種情報をダミー変数に変換してANNに入力するなどの手法の検討も行う必要がある。

謝辞：本研究において使用した、既往のトンネル工事において実施された探査データは、一般財団法人災害科学研究所トンネル調査研究会の活動の一環として提供を

受けたものである。同研究会委員長 松井保先生（大阪大学名誉教授）のご厚意、および本手法の適用性についてご議論いただいた委員各位に感謝の意を表す。

参考文献

- 1) 長谷川信介, 大津宏康: 地質リスクからみた山岳トンネルの地質調査における留意点, 土木学会論文集F4 (建設マネジメント), Vol.67, No.4, pp.169-180, 2011.
- 2) 中田雅博, 三谷浩二, 八木弘, 西塚郎, 西村和夫, 中川浩二: 観察記録の分析に基づく新しいトンネル切羽評価システムの提案, 土木学会論文集, No.623, pp.131-141, 1999.
- 3) 赤木渉, 佐野理, 進士正人, 西塚郎, 中川浩二: 山岳トンネル施工支援のための切羽評価法の適用性に関する研究, 土木学会論文集, No.686, pp.121-134, 2001.
- 4) *Japan Road Corporation : Design Procedure 3rd Collection Tunnel Edition*, p.71, 1997.
- 5) 斎藤康毅: ゼロから作るDeep Learning, pp.83-86, pp.199-201, オライリー・ジャパン, 2016.
- 6) 長谷川信介, 長谷川真吾, 北岡貴文, 大津宏康: 山岳トンネルの地山評価におけるニューラルネットワークの適用性, 日本材料学会, Vol. 67, No.3, pp.354-359, 2018.
- 7) 土谷陽太郎, 北岡貴文, 長谷川信介, 大津宏康: 多層ニューラルネットワークを用いた山岳トンネルにおける地山評価の検討, 第46回岩盤力学に関するシンポジウム講演論文集, pp.214-218, 2019.
- 8) 寺田学, 辻真吾, 鈴木たかのり, 福島真太郎: Pythonによるあたらしいデータ分析の教科書, pp.219-222, 翔泳社, 2018.
- 9) Aurélien Géron: scikit-learnとTensorFlowによる実践機械学習, pp.253-256, オライリー・ジャパン, 2018.
- 10) TensorFlow, <https://www.tensorflow.org/?hl=ja>
- 11) 伊藤真: Pythonで動かして学ぶ! あたらしい機械学習の教科書, 翔泳社, pp.192-197, 2018.
- 12) 日本応用地質学会岩盤分類再評価研究小委員会 (第二期): 若き技術者のための岩盤の地質工学的評価と分類, 古今書院, 2016.

EVALUATION OF ROCK CLASSIFICATION IN MOUNTAIN TUNNEL CATEGORIZED INTO SEDIMENTARY ROCK AND IGNEOUS ROCK BY USING NEURAL NETWORK

Yukitsugu MASUDA, Takafumi KITAOKA, Nobusuke HASEGAWA and Hiroyasu OHTSU

Rock classification in the mountain tunnel before construction is required to be improved from the viewpoint of geological risk reduction. Previous studies have suggested ground assessment methods using neural network. In this study, we first input the tunnel data normalized by the standard deviation into the neural network, and investigated the effect on the result. Next, in addition to physical properties, information on rock types (sedimentary rocks and igneous rocks) was also input to the neural network. As a result, it was shown that the accuracy can be improved by inputting rock type information.