

(35) ニューラルネットワークを用いた岩盤へのグラウチング注入効果の評価

EVALUATION SYSTEM ON GROUTING INTO ROCK MASS USING NEURAL NETWORK

安田 登* 松島 学**

Noboru YASUDA Manabu MATSUSHIMA

安田 武*** 熊谷浩二****

Takeshi YASUDA Koji KUMAGAI

It is very important to evaluate grouting works on improvement of the watertightness for planning to construct dam and process management. This paper presents that estimation system can be modeled based on neural network using lugeon unit, rock quality division and geological division data measured in-situ. This system shows the capability of evaluating grouting works quantitatively. Sensitivity analysis is carried out using this system developed. From analysis, an experience process and sense of engineer can described by model of relationship between lugeon unit and states of grouting put into rock mass.

Key Word: Neural Network, Grouting, Rock mass, Evaluation System, Lugeon Unit

1. まえがき

近年、ダム施工は立地点の枯渇化に伴い、地質構造や岩盤物性が複雑な地点で行われる場合が多くなっている。そのような場合、基礎岩盤の止水性向上を目的としたグラウチングの重要性が増大している。

ダム基礎岩盤のグラウト施工¹⁾は、グラウチング孔間に新たな追加のグラウチング孔を削孔し、止水性が確保されるまで繰返し行う工法（中央内挿法）で施工されている。追加のランチングを行うか否かは、孔内透水試験で得られるルジョン値分布図（ルジョンマップ）、グラウトの注入実績、地質状況などを基づいて判断される。グラウト効果判定は、一般にグラウト注入圧やグラウト注入量、ルジョン値などから現場技術者の経験的判断によって行われているため、技術者の個人差や曖昧さが含まれる。このように、グラウト効果判定は、工学的アプローチが遅れている分野であり、客観的データ以外の判断プロセスが加わるため、定量的な評価に至っていないのが現状である。このため、グラウトの効果を定量的に判定するモデルを構築することは、極めて意義がある。

一方、脳神経細胞を数学的に模擬したニューラルネットワーク手法^{2), 3)}は、曖昧性を含む多くのデータを効率的に処理したり、非線形のデータを含む問題に卓越した適合性があるといわれており、筆者らもコンクリート構造物の劣化評価⁴⁾、コンクリートの練混せ品質管理⁵⁾、景観評価⁶⁾などへの適用を通じてその有効性を明らかにしている。本研究は、このような観点からニューラルネットワークを用い、グラウト効果の判定および推定を行うシステムを構築し、その有効性を明らかにすることを試みたものである。

* 東京電力 電力技術研究所構造研究室 (〒230 横浜市鶴見区江ヶ崎町4-1)

** 工博 東電設計 技術開発本部耐震技術部 (〒110 台東区東上野3-3-3)

*** 東電設計 技術開発本部研究開発部 (〒110 台東区東上野3-3-3)

**** 工博 前田建設工業 技術研究所土質研究室 (〒179 練馬区旭町1-39-16)

2. グラウチング施工

亀裂のある複雑な岩盤に対するグラウチングの施工は、その目的や手法により数種類に分類され、今回検討の対象としたものは、岩盤内に鉛直方向の薄い壁状の不透水層を構築して、上流側の地下水の流れを遮断するカーテングラウチングである。

本研究に用いたデータは、カーテングラウチングの施工試験で得られた記録であり、パイロット孔の間隔は2.4mで深度5~45mまで5m毎に8ステージに区分されている。使用したデータはパイロット孔から3次孔までの施工実績を用いた。対象岩盤の地質は、安山岩、火碎岩ならびに角礫岩から構成されており、岩級区分はC₄級からC₁級まで広く分布している。グラウト注入圧力は深度方向に増加するように3~38kgf/cm²の範囲に設定されている。

3. システムの入出力

システムに用いるデータは、2.で示したように、3次孔まで行われたカーテングラウチングの試験データを用いている。試験データは、深度5m間隔の1ステージごとにルジオン値、グラウト注入圧力、グラウト注入量、岩級区分、および地質区分のデータが得られている。これら1ステージごとに得られているデータに基づいてニューラルネットワークの入出力データを作成した。

ニューラルネットワークにおける入出力データの関係は、図-1に示すとおりである。入力項目は、推定対象のn+1次孔の両側に隣接するグラウチング孔の同一ステージ（同一深度）における①ルジオン値②グラウト注入量③注入圧力④岩級区分⑤地質区分ならびに推定対象の孔自身の④岩級区分⑤地質区分である。また、⑥ステージの深度ならびに⑦孔間距離も位置関係を特定するために入力項目とした。出力項目は、n+1次孔におけるルジオン値とした。

ニューラルネットワークの精度は学習データの質と量に依存するため、試験施工中における取得データの吟味を行いデータの質を確保し、カーテングラウチング試験で測定された1次孔から3次孔の全データを用いることによりデータの量を確保した。

岩級区分は順序を含む定性的データであり、地質区分は順序を含まない定性的データである。ルジオン値、グラウト注入量、注入圧力、孔間距離、および深度は定量的データである。これらのデータ項目の特性を階層型ニューラルネットワークに反映させるため、データの分類を行った。各入力データ項目の作成方法について詳しく述べる。

(1) ルジオン値：透水試験から得られるルジオン値は、定量的データであるため、実数値を入力データとして作成した。入力データのルジオン値は、推定対象孔に隣接する左右両側2つの孔のデータを用いるため、2個のユニットのニューロンを設定した。

(2) グラウト注入量：グラウト注入量は、セメントを水で溶かしたセメントミルクの量であるが、濃度が異なる場合も考えられるため、セメントの絶対量とした。各注入孔に充填されたグラウト量は定量的データであるため、実数値を入力データとして作成した。このとき、入力データ項目のグラウト注入量は、隣接左右

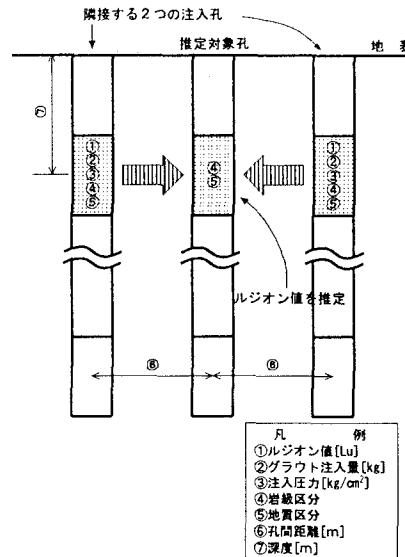


図-1 入出力項目の関係

2つの注入孔のデータを用いるため、2個のユニットのニューロンを設定した。

(3) 注入圧力：注入圧力は、セメントミルクが岩盤亀裂内へ浸透する際の抵抗あるいは難易度を表す定量的データであるため、実数値を入力データとして作成した。このとき、注入圧力は、隣接左右2つの注入孔のデータを用いるため、2個のユニットのニューロンを設定した。

(4) 孔間距離：孔間距離は、推定対象の注入孔と隣接する注入孔との距離を表す定量的データであるため、実数値を入力データとして作成した。左右両側の距離は等しいため1個のユニットのニューロンを設定した。

(5) 深度：深度は、地表からの深さを表す定量的データであるため、実数値を入力データとして作成した。入力データとして作成する深度は、地表から5m間隔に区分された1つのステージの深度範囲の重心位置までの距離と定義した。推定対象の注入孔の深度と隣接する左右2つの注入孔の深度は、全て等しいため1個のユニットのニューロンを設定した。

(6) 岩級区分：岩級区分の範囲は、1ステージごとの領域区分の範囲と必ずしも整合していないため、最も面積を占有している岩級区分により代表させた。また、岩級区分は、CH, CM, CLそれぞれの区分間にさらに2つの岩級を細分化しており、合計7段階の岩級区分としている。岩級区分は、順序のある定性的データとして取り扱えるため、1つの注入孔について、1ユニットのニューロンを設定し、表-1に示すとおり岩級区分を0～1の範囲で等分割する値に変換した。このとき、推定対象の注入孔と隣接する2つの注入孔のデータを用いるため、合計3個のユニットのニューロンを設定した。

(7) 地質区分：地質区分の設定も、岩級区分と同様に1ステージごとの領域で最も面積を占有している地質区分により代表させる。地質区分は順序のない定性的データであるため、使用するデータを(安山岩, 火碎岩, 角礫岩)の3区分としたことから、1つの注入孔に対して3個のユニットのニューロンを設定し、岩級区分を表-2に示すとおり変換した。このとき、推定対象の1つの注入孔と隣接する2つの注入孔を入力データとして作成するため、合計9(3区分×3孔)個のユニットのニューロンを設定した。

(8) 出力データ項目：入力データ項目のルジオン値と同様、透水試験より得られるルジオン値は、定量的データであるため、実数値を入力データとして作成し、1個のユニットのニューロンを設定した。

4. システムの構築

(1) システム

前章の入出力データ項目より入出力データのユニット数は、表-3に示すとおり入力データが合計20ユニット、出力データが1ユニットとなる。なお、左右中の表示のあるユニットは、それぞれ隣接する左右の孔と推定対象とする孔に対応するユニット数である。

一方、二維一ラルネットワークシステムの構築には、中間層数と中間ユニット数をどの程度にするかという問題があるが⁷⁾、筆者らの既往の研究^{4), 5), 6)}における経験から中間層数を一層、中間層のユニット数を入力データのユニットの1.5倍となる30ユニットに設定してシステムを構築した。

表-1 岩級区分の変換結果

岩盤区分	変換結果
CH級	1.00
CH(M)級	0.83
CM(H)級	0.67
CM級	0.50
CM(L)級	0.33
CL(M)級	0.17
CL級	0.00

表-2 地質区分の変換結果

岩級区分	変換結果
安山岩	1 0 0
火碎岩	0 1 0
角礫岩	0 0 1

表-3 システムの入出力項目一覧

	データ項目	ユニット数		
		左	中	右
入	ルジオン値 [Lu]	1	-	1
	グラウト注入量 [kg]	1	-	1
	注入圧力 [kg/cm ²]	1	-	1
	孔間距離 [m]	-	1	-
	深度 [m]	-	1	-
	岩級区分 [-]	1	1	1
力	地質区分 [-]	3	3	3
	合計	20		
出力	ルジオン値 [Lu]	1		

(2) 学習と検証データの選定

構築したシステムを検証するため、作成したデータを学習用のデータ（学習データ）とシステム検証用のデータ（検証データ）とに区別する必要がある。そこで、カーテングラウチング試験のデータから作成した全107件のデータを学習データと検証データに区分した。検証データの選定は、3次孔のルジオン値を出力値とするデータ群から出力値全体の分布をできるだけ代表する値11件を検証データとして選定し、残りの96件を学習データとして選定した。

(3) システムの認識結果

システムの構築は、一般孔のルジオン値を正解値として取り扱い、選定した96件の学習データを用いて、最大760回まで学習を行った。その時の学習データおよび検証データのシステム出力値と正解値の平均誤差と各学習回数の関係を図-2に示す。図より学習データの誤差平均は、学習を重ねるに従って減少する。特に、学習開始直後の誤差平均は著しく減少し、精度よく学習が行われていると言える。検証データにおいても、学習回数が10回付近で最も誤差平均が小さく、その後若干増加した後にほぼ一定値に収束する。今回は、学習データ、検証データともに誤差平均が十分に安定し、かつ最も小さいときの学習回数220回でシステムを構築することとした。

学習データの再認識結果を図-3に示す。この時の検証データの推定結果を図-4に示す。図の横軸はルジオン値の実測値を示し、縦軸は構築したシステムの出力値を示す。図より学習データの再認識結果は、十分な精度であることがわかる。検証データの推定結果は、絶対値誤差平均が8.15Luと本問題の複雑さを考慮すると実用的には高い推定精度と判断される。

構築したシステムの学習データと検証データの推定精度の分布を図-5および図-6に示す。図に見られるように、学習データの誤差は、平均値0.07Lu、標準偏差0.45Luとなり、検証データの誤差は平均値-1.64Lu、標準偏差11.13Luとなっている。これらの図からも学習データの推定精度は、誤差にもあまり偏りが無く十分な精度があることがわかる。

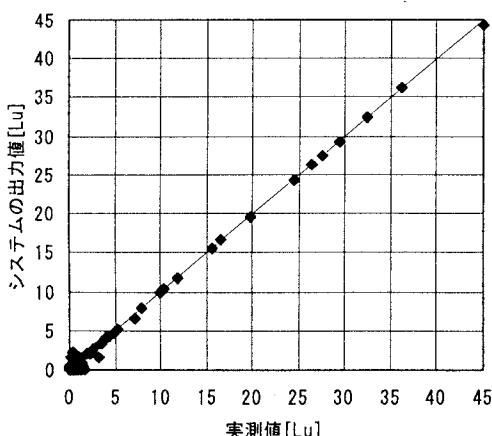


図-3 システムの出力値と実測値（学習データ）

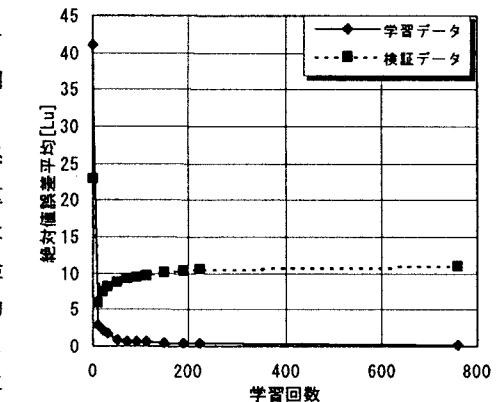


図-2 絶対誤差平均と学習回数

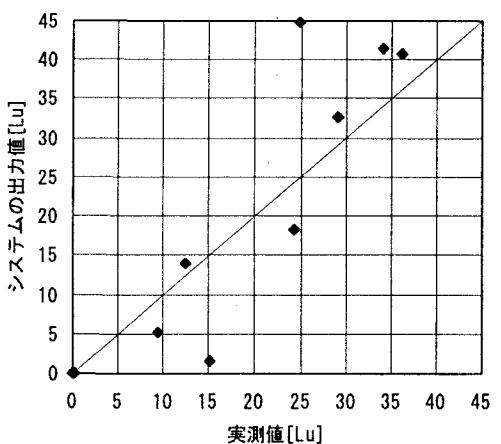


図-4 システムの出力値と実測値（検証データ）

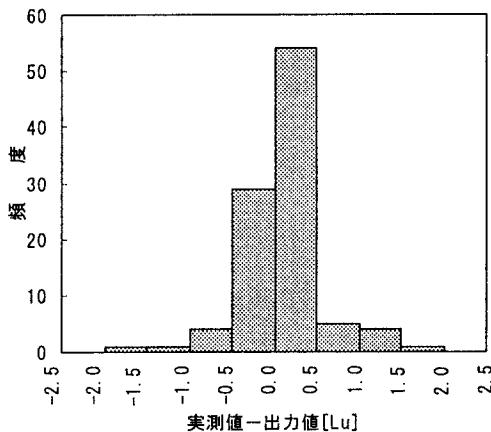


図-5 学習データの誤差分布

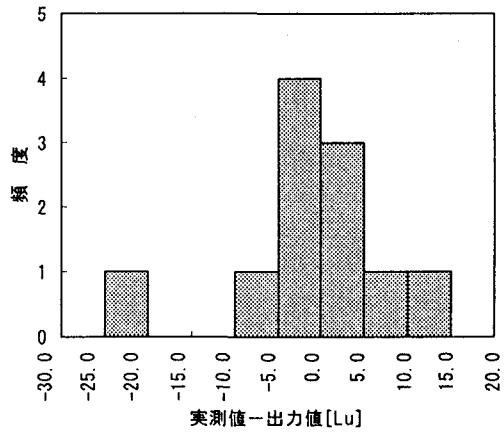


図-6 検証データの誤差分布

以上の結果から、本ニューラルネットワークを用いたシステムは岩盤の透水係数という複雑な構造のモデル化を考えると実用的には十分な精度でルジオン値の推定を行えるものと思われる。

5. 感度解析

感度解析は、多次元空間の一断面について、グラウト注入量を変化させることで調べた。感度解析のための入力は、注目する項目以外は、平均的なパターン近くのトレンドに注目するために表-4に示すような値を選んだ。従って、出力される結果は平均値周りの感度となる。

図-7は、学習を終了したシステムに対してグラウト注入量を得られたデータの最小から最大までを深度をパラメータに連続的に計算したものである。図に見られるようにグラウト注入量が増大するにつれて、ルジオン値が小さくなるのがわかる。さらに、図-8は、図-7を深度を横軸に取り書き換えたものである。図に見られるように、深度が深いとグラウト注入量にルジオン値は影響されないこともわかる。

このように、グラウト注入量が多くなるとルジオン値が指數的に下がること、深度が深くなるにつれてルジオン値がグラウト注入量に感度が無くなることなど、今まで現場経験者が持っていた知見を定量的に示すことができる。

6.まとめ

基礎岩盤におけるカーテングラウチング施工試験で測定されているデータを用いて、ニューラルネットワークに基づくグラウト効果の推定システムを構築した。本研究で得られた知見をまとめると、以下に示す通りである。

(1)グラウト効果を評価するためにルジオン値を推定するシステムをニューラルネットワークを用いて構築することができた。

表-4 感度解析の因子の設定

パター ン	1	2
ルジオン値 [Lu]	推定する3次孔に隣接したステージの 平均値を採用した。	
グラウト注入量 [kg]	実測で得られた値の最小から最大まで 変化させた。	
注入圧力 [kg/cm ²]	各深度ごとの平均値を採用した。	
孔間距離	3.310m	
深度[m]	7.5～42.5(5mピッチ)	
岩級区分	CH(M)級(全データの中央値)	
地質区分	角礫岩(全データの最頻値)	
図番号	図-7	図-8

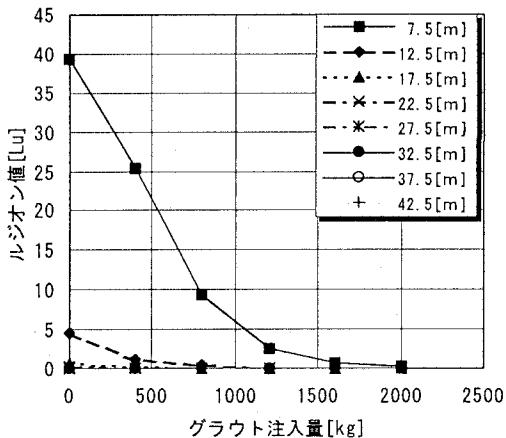


図-7 ルジョン値とグラウト注入量の関係

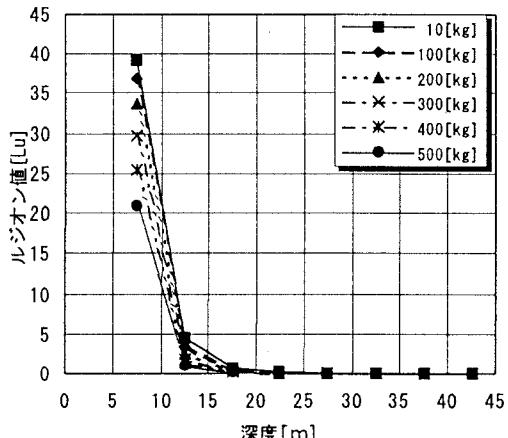


図-8 ルジョン値と深度の関係

- (2)実データを学習させたニューラルネットワークに未学習データを推定させる検証を行った結果、平均誤差は8ルジョン程度であり、実用的には十分な精度を持っている。
- (3)感度解析を行った結果、グラウト注入量が多くなるとルジョン値が指数的に下がること、深度が深くなるにつれてルジョン値がグラウト注入量に感度が無くなることなど、今まで現場経験者が持っていた知見を定量的に示すことができた。

参考文献

- 1)寺戸康隆:ダム基礎グラウチング(I)~(IX),ダム日本No.443~452,1981.9~1982.6
- 2)合原一幸:ニューロコンピュータ,東京電機大学出版局,1988.
- 3)高木英行:ニューラルネットワークの学習およびファジィと境界,日本ファジィ学会ファジィ推論とエキスパートシステムに関するワークショップ資料,1989.
- 4)安田 登,白木 渡,松島 学,堤 知明:ニューラルネットワークに基づいたコンクリート構造物点検技術者の思考過程の評価,土木学会論文集 No.496/V-24, pp.41-49, 1994.8.
- 5)安田 登,堤 知明,恒国光義,村上祐治:ニューラルネットワークを利用した超硬練りコンクリートの練り混ぜ品質管理手法の実プラントへの適用,コンクリート工学年次論文報告集 Vol.17 No.1, pp.1291-1296, 1995.6.
- 6)安田登,近田康夫,松島学,小堀為雄:緑化されたコンクリート擁壁の景観評価の逆解析,土木学会論文集, No.514/V-27, 55-64, 1995.5.
- 7)矢川元基:計算力学とCAEシリーズ12「ニューラルネットワーク-計算力学・応用力学への応用」,pp.146-148, 培風館, 1992.5.