

ニューラルネットワークによる 軌道振動応答の再現精度改善と未知量同定

IMPROVEMENT OF NEURAL NETWORK FOR DYNAMIC RESPONSE OF RAILWAY TRACK AND ITS APPLICATION TO IDENTIFICATION OF UNKNOWN PARAMETERS

阿部和久¹⁾, 高倉由浩²⁾

Kazuhisa ABE and Yoshihiro TAKAKURA

¹⁾新潟大学工学部建設学科

(〒 950-2181 新潟市五十嵐二の町 8050, E-mail: abe@eng.niigata-u.ac.jp)

²⁾新潟大学工学部建設学科

(〒 950-2181 新潟市五十嵐二の町 8050)

Enhancement of neural networks (NN) is attempted for the reproduction of dynamic response of railway track. In order for NN to reproduce the response with good accuracy, a spectrum ratio is represented by its size and profile in the NN. Moreover, employment of the logarithm of the size provides relative accuracy independent of the size. Numerical examples are presented to demonstrate the validity of the proposed method. The developed NN is used in an identification method that is constructed by means of the genetic algorithm, and good results are obtained.

Key Words : Neural Network, Track Vibration, Identification, Genetic Algorithm

1. はじめに

これまで著者らは列車走行により発生する軌道振動を予測する目的で、走行車輪・レール・まくらぎ・道床・地盤などから成る連成振動モデルを構築して來た^{1),2)}。これらの解析モデルによる軌道構造変更後の振動特性の予測には、まず現況の再現が重要となる。そのため、観測された振動加速度時刻歴を再現し得るレール頭頂面の凹凸形状の推定方法³⁾や、解析モデルにおける未知物性値の同定手法^{4),5)}の開発を試みた。文献⁴⁾では、観測データから未知物性値を同定する手法をニューラルネットワーク (NN) により構成した。概ね良好な結果を得たが、同定精度において改善を要する点も認められた。一方、同定に遺伝的アルゴリズム (GA) を用いる方法も、近年多く用されている。そこで文献⁵⁾で構成した方法では、まくらぎ/レールおよび基盤/レールのスペクトル比を再現し得る未知物性値の同定に GA を用い、その適用可能性について検討した。ただし、GA による探索過程において、上述のスペクトル比を求めるための順解析が必要となる。しかし、軌道振動解析には多大な時間を要するため、順解析の実行は現実的でない。そこで、NN を用い、物性値を入力、スペクトル比を出力とした振動応答再現過程を構成した。NN を順解析の代わりに用いることで、未知量の探索時間を大幅に短縮することが可能となつたが、同定精度のさらなる改善には、NN による再現性の向上が不可欠であることがわかつた。特に、スペクトル比が非常に小さい場合の同定精度が低く、スペクトル比の大小によらず一定の相対精度で再現することが必要に

思われる。

そこで本研究では、一定の相対精度の下でスペクトル比を再現し得る NN を構築し、GA による同定手法の精度改善を試みる。具体的には、スペクトル比の分布を、その代表値と形状とに分離し、代表値の対数表現とスペクトル形状とを NN により学習させる方法を探る。特に、それら 2 つの情報を同一の NN で再現する場合と、別々の NN で再現する場合とを対象に、再現精度の比較を行い、NN の適切な構成方法について検討する。さらに、構成した手法を未知物性値の同定に適用し、その有効性を検証する。

2. 車輪・軌道連成モデル

本研究では Fig.1 に示すような、車輪・レール・まくらぎ・道床・路盤等から成る連成モデルにおける未知物性値の同定を対象とする。特に、以下では地下鉄軌道を対象に議論を進める。その場合、Fig.1 の基盤より下部は、トンネル覆工・コンクリート基盤・地盤により構成されることとなる。

車輪には一定速度 c で走行する 2 車輪を考え、それを質点でモデル化する。レールは無限長 Euler ばかりで表現する。まくらぎは、弾性ばかりによりモデル化し、レールおよび道床との接触力は左右対称に作用するものと仮定する。道床・基盤以下の部分は二次元半無限波動場で表わし、有限要素・境界要素結合法により離散化する。軌道パッド、防振パッドなどのパッド類は Voigt ユニットで表わす。以上の軌道各部のモデル化の下で連成解析を

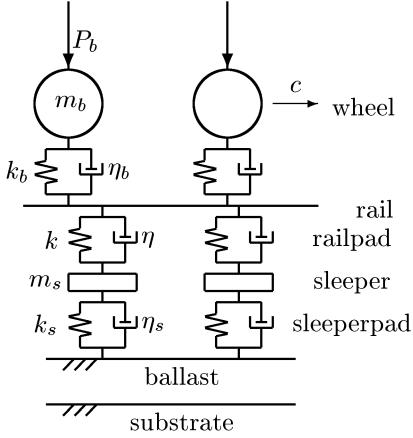


Fig. 1 Modeling of wheels and track.

行なう。その際に車輪・レール・まくらぎ・道床以下の各々に対し、1時間ステップに亘り単位力を加えた時の時刻歴応答を数値的Green関数として用いる。それらと作用力との合成積で各部の変位応答を与え、変位の適合条件を課すことで連成系の方程式を構成する¹⁾。

なお、解析時の振動源はレール頭頂面に設定した凹凸で与え、車輪・軌道系に内在する様々な不整を、それらと等価なレール凹凸として表現する³⁾。

3. GAによる未知物性値の同定

3.1 本研究における未知物性値

2.に示した数値モデルによる連成振動解析では、様々な物性値の設定が必要となる。その中で、パッド類の減衰係数は周波数に依存するため、実際の解析では適切な代表値を設定する必要がある。また、バラスト道床の剛性は、バラストの摩耗度により変動し、既設の軌道においては未知量の1つとなる。さらに、Fig.1のモデルのように道床以下を二次元モデルで表現した場合、本来三次元的に伝播する波動場が適切に表現されない恐れがある。そのため、現況再現には等価な剛性の設定が必要となる⁴⁾。以上のように、パッド類の減衰係数(η, η_s)と、道床・コンクリート基盤のせん断弾性係数(G_b, G_c)の合わせて4つの物性値が、特に事前設定の難しいパラメータであることより、本解析モデルにおいてはこれらの値を同定すべき未知量とする。

3.2 スペクトル比の処理

未知物性値は、まくらぎ／レール、コンクリート基盤／レールのスペクトル比の再現性に基づき同定する。なお、本問題における振動源は走行車輪であるため、スペクトル比は軌道系の物性値ばかりではなく、レール頭頂面に設定された凹凸形状にも依存する。そのため、スペクトル比からレール凹凸の影響を排除する必要がある。ここでは、同一の物性値の下でいくつかのレール凹凸に対し振動解析を行い、それらの単純平均により得られたスペクトル比を同定に用いる。また、100Hz以下と400Hz以上の周波数域において、レール凹凸の影響が特に顕著

に認められたので⁴⁾、100～400Hzの範囲のスペクトル比を採用する。以下に示す未知物性値の同定では、この範囲の周波数域をさらに7等分し、各区間毎に平均化して得られる離散値を用いる。

3.3 GAによる同定

未知量の同定に最急降下法や共役勾配法などの直接定式化法を用いる場合、未知量の値を更新しながら順解析を反復する必要がある。本問題の連成解析には多大な時間を要するので、順解析を同定過程に直接用いることは効率的でない。そこで本研究ではスペクトル比の再現にNNを用いる。ただし、上述のような直接定式化法による場合、スペクトル比の未知物性値に関する導関数を精度良く求める必要があり、NNによる再現には導関数レベルでの再現精度が要求されることとなる。一方、GAによる同定では導関数の評価を必要としないので、1階微分のレベルでの関数近似は不要であり、NNに過度な再現精度を要求しなくてすむ。そこで、未知物性値の探索にはGAを用いる。

GAは、生物が多く世代に亘り進化を続け、淘汰され次第に環境に適応していく過程を模倣し、それを最適化の手法に取り入れたものである。GAでは最適値を見出す空間内の探索点を個体と呼ぶ。一般に、各個体は探索空間の座標を二進数表現したものより定義されるが、この場合コード化とデコード化を必要とし、実数変数を対象とする場合、必ずしも効率的ではない。そこで探索空間の座標を直接実数表現する実数型GAを用いる。本研究では、各個体は4つのパラメータ対 $\mathbf{x} := (\eta, \eta_s, G_b, G_c)$ により表現されることとなる。

各個体の適合度は、スペクトル比の離散値 \mathbf{y} により与えられる次の目的関数 F より作成する。

$$F(\mathbf{x}_i) = \|\bar{\mathbf{y}} - \mathbf{y}(\mathbf{x}_i)\| \quad (1)$$

ここで、 $\bar{\mathbf{y}}$ は規定されたスペクトル比の離散値からなるベクトル、 $\mathbf{y}(\mathbf{x}_i)$ は個体 \mathbf{x}_i に対して得られるスペクトル比であり、 $\|\cdot\|$ はユークリッドノルムで与える。なお、スペクトル比の各成分の相対誤差に基づき目的関数 F を定義する方法についても検討したが、式(1)の目的関数と比較して有意な差が認められなかったので、ここでは式(1)による場合を考える。

適合度 $\Phi(\mathbf{x}_i)$ は F に基づき次式で定義する。

$$\Phi(\mathbf{x}_i) = \max\{F(\mathbf{x}_j) ; j = 1, \dots, N\} - F(\mathbf{x}_i) \quad (2)$$

ここで N は個体数である。式(2)の Φ は適合度の高い個体ほど高い値をとる。

以上に定義した適合度の下で、再生・交叉・突然変異といったGAの操作を世代毎に繰り返し実行する。なお、再生にはルーレット選択を⁶⁾、実数型GAの下での交叉には古川・矢川⁷⁾の方法を用いた。また、GAの終了条件は世代数の上限値により規定した。

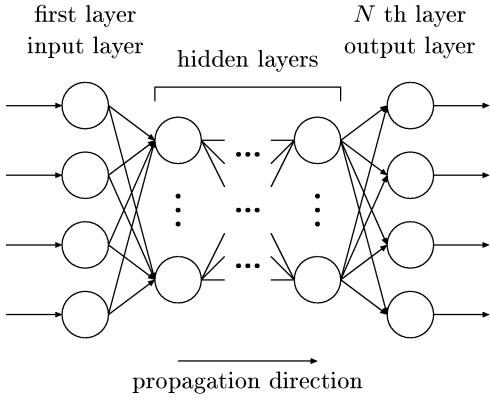


Fig. 2 Hierarchical neural network.

4. NN による振動応答の再現精度の改善

4.1 従来法

文献⁵⁾では未知物性値 (η, η_s, G_b, G_c) を入力、スペクトル比 \mathbf{y} (14成分) を出力とした Fig.2 に示すような階層型 NN を構成した。なお、学習には一括型誤差逆伝播則⁸⁾を用い、各物性値が一般的にとり得る値の範囲で、Table.1 に示す合計 625 パターンの学習データの下で学習を行っている。全体には概ね良好な再現がなされていたものの、一部の物性値に対しては依然大きな相対誤差を伴っていた。再現精度に大きな誤差の認められた学習パターンに対する基盤／レールのスペクトル比の例を Fig.3 に示す。この図は η (kNs/m), η_s (kNs/m), G_b (MPa), G_c (GPa) の値が (900, 10, 90, 23) の場合に対応している。当該条件ではバラスト道床の剛性が比較的高く設定してある。そのため基盤／レールのスペクトル比のレベルが非常に低くなり、大きな相対誤差を生じたものと考えられる。ちなみに絶対誤差は 1×10^{-5} 程度であり、他の学習パターンと比べ特段大きな値ではない。なお、まくらぎ／レールのスペクトル比においては高い再現精度が得られていた。

Table 1 Learning data.

η (kNs/m)	100	300	500	700	900
η_s (kNs/m)	10	30	50	70	90
G_b (MPa)	30	45	60	75	90
G_c (GPa)	19	20	21	22	23

4.2 提案する方法

従来法による同定精度の低下は前述のように NN による再現精度の低下によるものと思われる。そこで本研究ではスペクトル比のレベルによらず常に一定の相対精度を維持し得る方法について検討する。

3.2 に述べたように各スペクトル比は 7 つの離散値で与えられている。まくらぎ／レールのスペクトル比を y_{si} ($i = 1, \dots, 7$)、基盤／レールのスペクトル比を

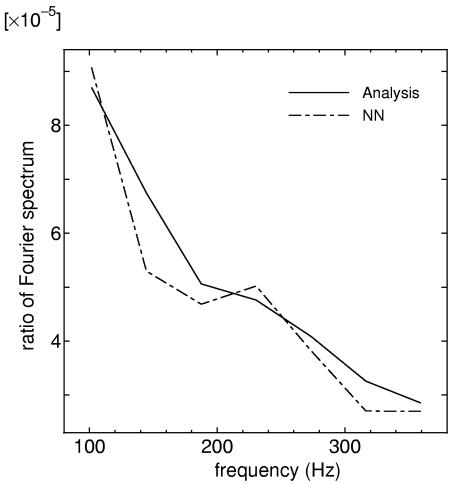


Fig. 3 Spectrum ratio of basement/rail for $(\eta, \eta_s, G_b, G_c) = (900, 10, 90, 23)$.

y_{bi} ($i = 1, \dots, 7$) とする。ここで y_{si}, y_{bi} は周波数の低いものから順に並べられているものとする。NN によるスペクトル比の再現において、スペクトル比をその代表値とそれに対する相対値とに分離して考える。代表値には最も低い周波数におけるスペクトル比 y_{s1}, y_{b1} を用いる。さらに NN による再現がスペクトル比の大小によらず一定の相対精度でなされるように、 y_{s1}, y_{b1} の対数値 $\log y_{s1}, \log y_{b1}$ をとり、この値を NN の出力に用いる。この場合、NN で扱う出力データは次の諸量 f_{si}, f_{bi} により与えられることとなる。

$$\begin{aligned} f_{s1} &:= \log y_{s1}, \\ f_{sj} &:= \frac{y_{sj}}{y_{s1}} \quad (j = 2, \dots, 7), \\ f_{b1} &:= \log y_{b1}, \\ f_{bj} &:= \frac{y_{bj}}{y_{b1}} \quad (j = 2, \dots, 7) \end{aligned} \quad (3)$$

本研究では式 (3) で定義された f_{si}, f_{bi} を出力する NN として、全データを单一の NN により学習・出力させる方法 (Case1) と、 f_{s1}, f_{b1} を学習・出力する NN (NN_1) とその他の値 f_{sj}, f_{bj} ($j = 2, \dots, 7$) を学習・出力する NN (NN_2) の 2 つの NN を用いる方法 (Case2) の 2 ケースを対象に検討を行なう。

なお、全成分を対数表現する方法についても検討したが、上の 2 ケースに比べ NN の再現精度が劣っていたので、ここでは省略する。また、通常の NN を 2 分する方法によっても学習効果は幾分向上すると思われるが、相対精度の向上は期待できない。

5. 解析例

5.1 解析条件

解析時の初期時刻 ($t=0$) における車輪位置、まくらぎ配置等を Fig.4 に示す。振動発生源であるレール凹凸は 6.62m 区間に設定し、その中心位置でレール、まくらぎ、コンクリート基盤上面における振動加速度を観測するも

のとする。なお、車輪の走行速度は 20 (m/s) とし、解析時の時間増分は $\Delta t=1/1000$ (s) としている。

道床以下の部分はバラスト道床・バラストマット・コンクリート基盤・半無限地盤より成るものとし、Fig.5 のように有限要素と境界要素により離散化している。解析において設定した諸パラメータの値を Table.2, 3 に示す。なお、地盤の物性値は弾性波試験等より概ね知ることができる。その他の物性値は敷設段階で既知なものである。

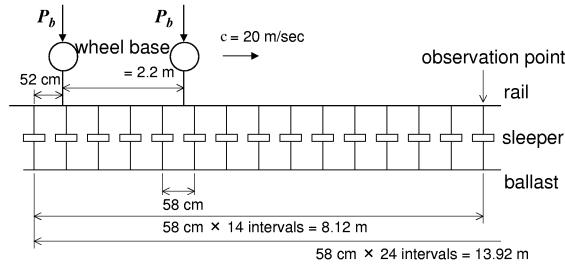


Fig. 4 Analytical conditions of wheels, rail and sleepers.

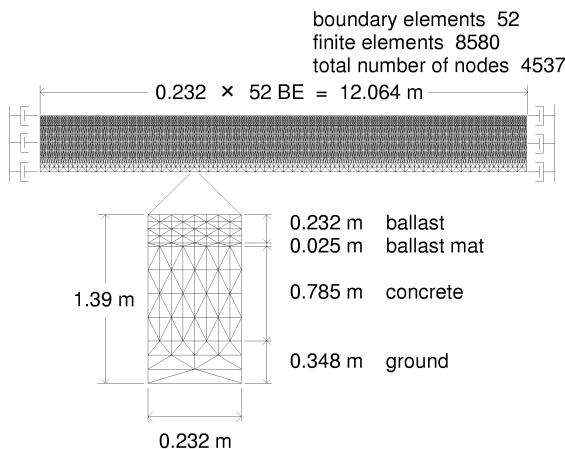


Fig. 5 Coupled mesh for the sleeper support.

5.2 NN によるスペクトル比再現精度の検討

Table.1 に示した 625 パターンの教師用データを順解析により作成し、その下で NN の学習を行った。学習は一括型誤差逆伝播則により Case2 の NN₁については 20 万回、その他の NN については 10 万回まで実施し、その結果を用いたことによる学習速度の低下は特に認められなかつた。また、Case1 の NN の構造は、入・出力層と中間層二層、Case2 の NN の構造は、入・出力層と中間層一層から成るものを用いた。なお、学習精度に基づく検討の結果、各層のユニット数を Table.4 のように設定した。

従来法により良好な再現精度の得られなかつた学習データ (η, η_s, G_b, G_c) = (900, 10, 90, 23) に対して本手法を適用した結果を Fig.6 に示す。なお、図には比較のため、

Table 2 Parameters of wheel, rail, sleeper and pads.

weight of car body	P_b	(kN)	36.75
mass of wheelset	m_b	(kg)	350
spring const.	k_b	(MN/m)	2000
flexural rigidity of rail	EI	(MN·s/m)	4
mass of rail	ρA	(kg/m)	50
spring const. of railpad	k	(MN/m)	110
spring const. of sleeperpad	k_s	(MN/m)	9
elastic modulus of sleeper	E_{sc}	(MPa)	2×10^4
mass of sleeper	W_s	(kg)	205
elastic modulus of PC steel	E_{ss}	(MPa)	1.9×10^5

Table 3 Parameters of sleeper suport.

ballast	density	ρ_b	(kg/m ³)	1667
	Poisson's ratio	ν_b		0.3
mat	density	ρ_m	(kg/m ³)	1227
	longitudinal wave vel.	V_{mp}	(m/s)	70.65
	trasverse wave vel.	V_{ms}	(m/s)	49.96
	shear modulus	G_m	(MN/m ²)	3.06
concrete	density	ρ_c	(kg/m ³)	2300
	Poisson's ratio	ν_c		0.2
ground	density	ρ_g	(kg/m ³)	1420
	longitudinal wave vel.	V_{gp}	(m/s)	928
	trasverse wave vel.	V_{gs}	(m/s)	270
	shear modulus	G_g	(MN/m ²)	103.5

解析で得たものを実線で、従来法によるものを一点鎖線で合わせて示した。図より、まくらぎ／レールのスペクトル比についてはいずれの NN によっても十分な精度で再現がなされていることがわかる。一方、基盤／レールのスペクトル比について見ると、従来の NN では大きな誤差を伴いその形状自体適切に再現できていない様子が認められる。また、Case1 では、分布形状の再現性は良好であるが、全体に大き目の値を与えており、スペクトル比の代表値 y_{b1} の再現精度に問題があることがわかる。これに対し、Case2 の NN では、スペクトル比の分布形状・値共に良好な再現精度が得られている。Case2 では、スペクトル比の代表値 y_{s1}, y_{b1} と、それ以外の相対量とを別の NN で扱っているため、特に代表値を出力する NN の学習が効率良く実行でき、その結果上述のような差異が現れたものと思われる。

次に、学習データ以外の物性値(未学習データ)を対象に各 NN で再現した結果を Fig.7 に示す。図は (η, η_s, G_b, G_c) = (800, 40, 100, 23.5) に対するものである。従来法では、やはり形状・値共に大きな誤差を伴っていることがわかる。この設定に対しては Case1 が Case2

よりわずかに良好な結果を与えている。いずれの手法によても、Fig.6 に示した学習データの場合程の再現精度は得られていないが、本手法を用いることで概ね妥当な結果が得られていることが確認できる。

なお、全学習データを対象に Case1 と Case2 の再現精度を比較した結果を Table.5 に示す。この表は、スペクトル比の代表値 f_{b1} とその分布形状 f_{bj} の再現精度を相対誤差の最大値で表わしたものである。Case2 の誤差は Case1 の約 $1/2$ となっており、このことからも Case2 の有効性が確認できる。

Table 4 Structure of neural networks.

	Input	Hidden	Output
Case1	4	16	14
Case2	NN ₁	4	23
	NN ₂	4	17
			12

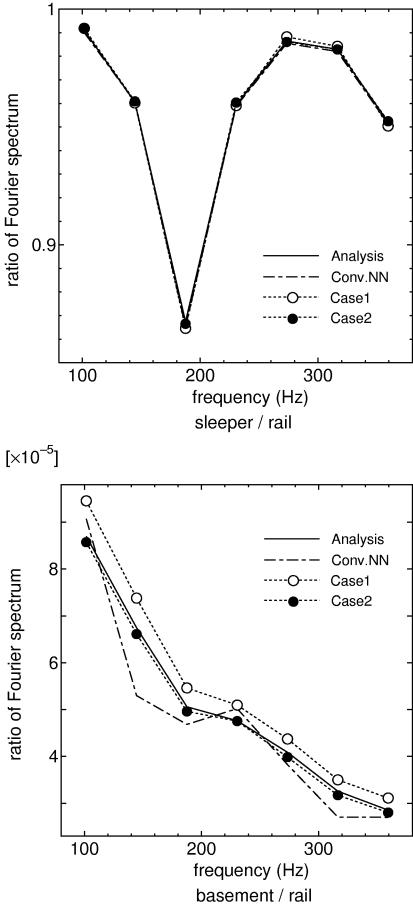


Fig. 6 Reproduction of spectrum ratio by NNs for $(\eta, \eta_s, G_b, G_c) = (900, 10, 90, 23)$.

5.3 GA による物性値同定

本研究で構成した NN を 3. に示した GA の中で用い未知物性値の同定を行った。ここで、GA の各世代における個体数は 1000 とし、操作の終了は 1000 世代とした。

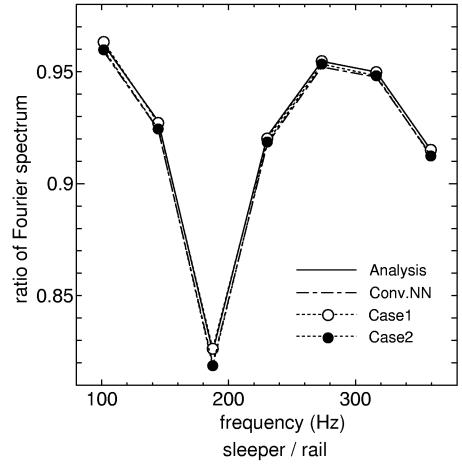


Fig. 7 Reproduction of spectrum ratio by NNs for $(\eta, \eta_s, G_b, G_c) = (800, 40, 100, 23.5)$.

Table 5 Comparison of accuracy.

	f_{b1}	f_{bj}
Case1	18.2%	6.6%
Case2	7.0%	3.3%

同定結果を Table.6 に示す。表は、 G_b, G_c が比較的大きな値の場合 (Test1)，小さな値の場合 (Test2)，および、各物性値が学習データの設定範囲の中央値に概ね対応している場合 (Test3) での結果を示している。なお、比較のため、Case1,2 の NN に加え、従来法による NN を用いた場合も合わせて示した。いずれの設定値に対しても本手法を適用することで、従来法に比べ同定精度が概ね向上している。特に、Test1 と Test3 においては Case2 の NN を用いることで極めて良好な結果が得られていることがわかる。Test2 においては、Case2 の NN を用いた場合でも G_b の同定誤差が 16% であり、他の設定値に比べ低い精度となっている。しかし、従来法では 37% の誤差が生じており、本手法の適用により同定精度が大幅に改善されている様子が窺える。

Table 6 Identification by GA with various NNs.

	η	η_s	G_b	G_c
Test1	800	40	100	23.5
Conv.NN	796.33 (-1%)	34.887 (-13%)	104.53 (+5%)	23.084 (-2%)
Case1	793.59 (-1%)	39.128 (-2%)	98.534 (-2%)	23.522 (0%)
Case2	821.71 (+3%)	39.620 (-1%)	98.658 (-1%)	23.620 (+2%)
Test2	600	80	25	18.5
Conv.NN	599.99 (0%)	85.876 (+7%)	15.836 (-37%)	21.403 (+16%)
Case1	622.11 (+4%)	88.976 (+11%)	20.344 (-19%)	21.370 (+16%)
Case2	606.04 (+1%)	81.079 (+1%)	21.001 (-16%)	20.527 (+11%)
Test3	600	40	65	21
Conv.NN	590.41 (-2%)	38.073 (-5%)	67.891 (+4%)	20.551 (-2%)
Case1	605.63 (+1%)	40.242 (+1%)	65.392 (-1%)	20.895 (-1%)
Case2	595.80 (-1%)	40.091 (0%)	64.246 (-1%)	20.990 (0%)

6. おわりに

軌道振動系における未知物性値の同定に用いる NN の再現精度の向上を試みた。まくらぎ／レールと基盤／レールのスペクトル比を NN で精度良く再現するために、NN 内においてスペクトル比を、その代表値と分布形状とに分離して表現する方法を探った。さらに、スペクトル比の代表値を対数表現することで、その値の大小によらず一定の相対精度の下で再現可能な NN を構築した。解析例を通して検討した結果、従来用いていた NN に比べ、提案手法は再現精度が高く、十分順解析の代用となり得ることがわかった。また、本手法を GA による未知物性値

の同定に適用した結果、同定精度の向上が認められ、その有効性が確認できた。

本研究では NN を一種のデータ補間として用いている。その意味では Lagrange 補間などの従来法による方法も考えられる。実際の解析では GA の下で多数回補間の操作を実施する必要があり、精度の面だけでなく計算効率についても配慮の上、どのような方法が適切であるかを判断することが重要である。特に、本論文では格子点上の全物性値データを用いたが、NN による学習においては、それよりランダムに抽出した一部のデータのみを用いることも可能と思われ、これらの点に基づいた有効性に関する議論も今後必要に思われる。

なお、本論文では道床以下を二次元でモデル化したため、コンクリートの等価剛性 G_c も未知量として扱った。今後は、ここに構成した同定手法を三次元モデル²⁾に適用することで、より現実的なモデル化の下での振動特性の評価が可能になるものと考えている。

参考文献

- 1) 阿部 和久、須田 雅樹、古田 勝：車輪・軌道・地盤系の連成振動解析手法、構造工学論文集、Vol.45A、271-280, 1999.
- 2) 鈴木 貴洋、阿部 和久：三次元地盤モデルを用いた軌道系連成振動解析、平成 13 年鉄道技術連合シンポジウム講演論文集、121-124, 2001.
- 3) 阿部 和久、鈴木 貴洋、古田 勝：軌道振動系におけるレール頭頂面の凹凸形状の推定、応用力学論文集、Vol.3, 107-114, 2000.
- 4) 鈴木 貴洋、阿部 和久、古田 勝：ニューラルネットワークによる軌道振動系の物性値同定、BTEC 論文集、Vol.10, 55-60, 2000.
- 5) 阿部 和久、佐藤 大輔、古田 勝：遺伝的アルゴリズムによる軌道振動モデルの未知パラメータ同定、鉄道力学論文集、第 5 号、55-60, 2001.
- 6) 坂和 正敏、田中 雅博：遺伝的アルゴリズム、朝倉書店、1995.
- 7) Furukawa, T. and Yagawa, G. : Inelastic constitutive parameter identification using an evolutionary algorithm with continuous individuals, Int. J. Num. Meth. Engng, 40, 1071-1090, 1997.
- 8) 矢川 元基 編：ニューラルネットワーク、培風館、1992.