

多目標最適化手法へのニューラルネットワークの応用

齊藤 進¹・堀井健一郎²・依田照彦³

¹正会員 工修 八戸工業高等専門学校校助教授 建設環境工学科(〒039-11 青森県八戸市田面木字上野平16-1)

²正会員 早稲田大学教授 理工学部土木工学科(〒169 東京都新宿区大久保3-4-1)

³正会員 工博 早稲田大学教授 理工学部土木工学科(〒169 東京都新宿区大久保3-4-1)

実際の設計や計画における最適化問題では、設計条件・設計変数や制約関数・目的関数の一部が定性的データであったり、両者が定量的であってもその関係が数式によって陽に表現できないことなどがある。このような場合の最適化手法として、ニューラルネットワークの応用が有効である。本研究では、まずニューラルネットワークを応用した最適化手法が、従来の数理的最適化法に代わり得るものであることを、構造最適設計の例によって示す。その後、数理的最適化法では最適化が難しい問題も、ニューラルネットワークによって最適化が容易になることを、コンクリートの配合最適設計の例によって明らかにする。

Key Words : neural networks, multiobjective optimization, goal programming

1. まえがき

1970年前後より、数理計画法のような数理的最適化法が、構造最適設計をはじめとする最適化問題に盛んに応用されてきた。数理的最適化法が適用できるためには、設計変数、制約関数、目的関数が定量的に表現できる必要があり、設計変数と制約・目的関数の関係が数式によって陽に表現できなければならない。このことは実際の設計や計画の問題を、採用する数理的最適化法に合わせて単純なモデルに置き換えることを意味し、そのために満足できる結果が得られないこともある。

最適化問題をより実際に近い形で扱おうとすると、定性的あるいは主観的な要因(設計条件・設計変数)や判断基準(制約・目的関数)を取り入れる必要が生じる。また、両者が定量的であってもその写像関係が数式によって陽に表現できない場合も考慮しなければならない。このような場合は従来の数理的最適化法によっては対処が難しく、新しい観点に立った最適化手法が必要となる。

ところで近年、人間の神経細胞(ニューロン)のモデルをネットワーク化し、脳の中の情報処理を模倣したニューラルネットワークの研究・応用が諸分野において盛んに行われており多くの成果^{1)~3)}が得られている。土木工学分野においても、交通計画⁴⁾、損傷評価^{5)~9)}、景観評価^{10)~14)}、コンクリートの品質管理^{15)~17)}など多方面においてその応用が試みられつつある。構造工学の分野においても、構造解析¹⁸⁾や最適設計^{19)~21)}な

どにニューラルネットワークが応用されている。

ニューラルネットワークはそのネットワークの構造によって、階層型と結合型に大別されるが、階層型ニューラルネットワークは、以下の特質をもつため結合型に比べ応用範囲が広いといえる。

- “学習”によって多入力と多出力の間で非線形写像が可能になる。
- 精度はデータの性質に依存するが、学習済みネットワークは、未学習の入力に対しても迅速に出力値および感度係数の推定ができる。(汎化能力)
- 学習済みネットワークによって、出力が目標値に合致するように入力値を迅速に更新できる。また、出力が目標値以下(以上)になるように入力値を更新できる。(最適化能力)
- ネットワークをモジュール型とすることができ、その結果モジュールごとに学習をしたり、出力を任意に追加・削除することができる。
- 入力・出力データとして連続値だけでなく、離散値や定性的データも扱うことができる。

以上から本研究では、多目標最適設計問題を念頭において、以下の3種類のニューラルネットワークの応用を考える。

- “解析器(Analyzer)”としてのニューラルネットワーク
- “最適化器(Optimizer)”としてのニューラルネットワーク
- 異なる設計条件に対応した最適化器としてのニュー

ラルネットワーク

解析器は学習済みネットワークの汎化能力を、最適化器は最適化能力を応用するものである。設計問題では入力設計条件・設計変数に、出力は制約関数・目的関数に対応する。また本研究では、次の2つの具体的問題にニューラルネットワークを応用する。

● トラスの多目標最適設計

入力・出力が連続値であり、両者の関係が、数式によって陽に表現できる場合の最適化問題の例としてトラスの多目標最適設計を取り上げる。構造最適設計におけるニューラルネットワークの応用は、Berkeら¹⁹⁾、田中²¹⁾によって示されているが、本研究では特に従来法である目標計画法と対比させながら、ニューラルネットワークの有効性を検討する。

● コンクリートの配合最適設計

離散値や定性的データを含み、入力と出力の関係が数式によって陽に表現できない最適化問題の例として、コンクリートの配合設計問題を取り上げる。大矢ら¹⁶⁾はコンクリートの品質の最適化にニューラルネットワークを応用する方法を示している。解析理論のない分野においても最適化を試みる方向は同じであるが、本研究では、実験データから解析器としてのニューラルネットワークが構築できれば、構造最適設計の場合とまったく同じように種々の最適化が可能であることを示す。

すなわち、本研究の目的は、3種類のニューラルネットワークの応用の方法を、性質の異なる2つの最適化問題に共通に試みることによって、最適化手法としてのニューラルネットワークの有効性や汎用性を明らかにすることにある。なお、本研究では実用性を考慮して、計算は NEC PC9821 Xa10 を用いて行った。

2. ニューラルネットワークの学習過程

(1) 階層型ニューラルネットワーク

階層型ニューラルネットワークは、図-1に示すような人工ニューロン(ユニットと呼ぶ)を、結合荷重 w_{ij} を介して、図-2に示すような階層型のネットワークとして結合したものである。ユニットの出力 $y_i^{(m)}$ は、 $\theta_i^{(m)}$ をしきい値として、

$$x_i^{(m)} = \sum_{j=1}^{N_{m-1}} w_{ij}^{(m)} y_j^{(m-1)} - \theta_i^{(m)} \quad (1)$$

$$y_i^{(m)} = F[x_i^{(m)}] \quad (2)$$

より計算される。ただし $\theta_i^{(m)}$ は1を出力する $y_0^{(m-1)}$ の結合荷重 $w_{i0}^{(m)}$ として処理され、また、 $x_i^{(m)}$ は出力




図-1 人工ニューロン




図-2 階層型ニューラルネットワーク

関数(シグモイド関数)、

$$F[x] = 1/(1 + e^{-\epsilon x}) \quad (3)$$

による変換を受けるものとする。式(3)の ϵ はシグモイド関数の傾きを決める定数である。図-2の第0層(入力層)のユニットにデータが入力されれば、式(1)~式(3)に従って順次各層のユニット出力が計算され、最後に第M層(出力層)のユニットよりネットワークとしての出力がなされる(順伝播)。

(2) ニューラルネットワークの学習

学習データとして一組の入力 $y_j^{(0)}$ ($j = 1, 2, \dots, N_0$) と期待出力 d_i ($i = 1, 2, \dots, N_M$) が与えられた時、ネットワークの出力 $y_i^{(M)}$ ($i = 1, 2, \dots, N_M$) が d_i に近づくように結合荷重 w_{ij} を更新することを“学習”という。具体的には誤差関数、

$$E = \frac{1}{2} \sum_{i=1}^{N_M} (y_i^{(M)} - d_i)^2 \quad (4)$$

を定義し、結合荷重を、

$$w_{ij}^{(m)}[n+1] = w_{ij}^{(m)}[n] - \eta(\partial E / \partial w_{ij}^{(m)}) \quad (5)$$

に従って更新することによって E の極小値を求める。式(5)において n は学習サイクルを表し、 η ($\eta > 0$) は

収束速度を決めるパラメータを表す。また、通常は式(5)の右辺に1サイクル前の結合荷重の変化に比例した項(慣性項という、 α は比例定数)、

$$\alpha(w_{ij}^{(m)}[n] - w_{ij}^{(m)}[n-1]); \quad 0 < \alpha < 1 \quad (6)$$

を加えて収束を速める。式(5)の $(\partial E / \partial w_{ij}^{(m)})$, ($m = 1, 2, \dots, M; i = 1, 2, \dots, N_m; j = 0, 1, \dots, N_{m-1}$)の計算は、通常のバックプロパゲーション法¹⁾による。なお、式(4)~式(5)は一組の学習データに対する式であり、複数組の学習データに対しては、一組ごとに結合荷重を更新する逐次法か、修正量を加算した後一括して結合荷重を更新する一括法によって対処する。

(3) 学習における諸設定

実際のニューラルネットワークの学習において事前に設定する事項を以下に述べる。

- ネットワークのトポロジー
ネットワークにはモジュール型と一体型があるが、最適化問題にはモジュール型が適する²¹⁾。トラスの最適設計例における学習では、一体型も性能比較の対象とするが、最適化計算に実際に用いるネットワークはすべてモジュール型である。またすべてのネットワークの中間層の数は1つとする。
- 入力・出力ユニットの種類
トラスの最適設計では、データはすべて連続値であるのでアナログ値ユニットを用いる。コンクリートの配合最適設計では、離散値や定性的データが一部含まれており、これらにはデジタル値ユニットを用いる。
- 入力・出力データの前処理(スケーリング)
すべての入力・出力データを0.1~0.9の範囲にスケーリングする。誤差の評価はすべてスケーリングされた値のままで行う。
- 結合荷重の初期値と修正方法
初期値は一樣乱数によって与え、修正には逐次法を用いる。

また、学習を行いながら試行錯誤的に設定していくものとして、学習パラメータ η, α, ϵ 、学習データの数、出力誤差の制限値、学習回数などがあるが、これらについては実際の応用例に即して述べる。

3. ニューラルネットワークの多目標最適化への応用

(1) 目標計画法の定式化

本研究においては“従来の数理的最適化法”として目標計画法を用いる。一般的な目標計画法は次のように定式化²²⁾されている。

find $X = \{x_1, \dots, x_n, \dots, x_N\}$ to minimize

$$A = \left[\sum_{i \in I_1} (w_i^+ d_i^+ + w_i^- d_i^-), \dots, \sum_{i \in I_k} (w_i^+ d_i^+ + w_i^- d_i^-), \dots, \sum_{i \in I_K} (w_i^+ d_i^+ + w_i^- d_i^-) \right] \quad (7)$$

subject to

$$\begin{aligned} f_i(X) - d_i^+ + d_i^- &= \hat{f}_i \quad (i = 1, 2, \dots, I) \\ d_i^+ \cdot d_i^- &= 0, d_i^+ \geq 0, d_i^- \geq 0 \quad (i = 1, 2, \dots, I) \\ g_j(X) &\leq 0 \quad (j = 1, 2, \dots, J) \\ x_{n, \min} &\leq x_n \leq x_{n, \max} \quad (n = 1, 2, \dots, N) \end{aligned}$$

上式において X は N 次元設計変数ベクトル、 $f_i(X) - d_i^+ + d_i^- = \hat{f}_i$ は目標制約式、 $f_i(X)$ は目的関数、 \hat{f}_i はその目標値、 d_i^+ は超過差異変数、 d_i^- は不足差異変数である。 A は達成関数と呼ばれ、この式の中の $I_k \neq \phi$ は k 番目の優先順位のクラスに属する目的関数の添字の集合を表し、また w_i^+, w_i^- は重み係数で目標達成の相対的な優先度を表す。 K は優先順位の区分数で $1 \leq K \leq I$ である。 $g_j(X) \leq 0$ は制約条件式であるが、実際の計算では本来の目標より優先度の高い“目標”として取り扱うため、制約条件と目標の区別はなくなる。すなわち、 $g_j(X) - d_j^+ + d_j^- = 0$ とし $d_j^+, (j = 1, 2, \dots, J)$ を優先的に最小化すればよい。

次に制約条件も含めて目標として考えられるタイプとその達成法を示す。

- (a) $f_i(X) = \hat{f}_i$ となしたい場合は $d_i^+ + d_i^-$ を最小化。
 - (b) $f_i(X) \leq \hat{f}_i$ となしたい場合は d_i^+ を最小化。
 - (c) $f_i(X) \geq \hat{f}_i$ となしたい場合は d_i^- を最小化。
- $f_i(X)$ を最小化したい場合は、 \hat{f}_i を予想される最小値より小さな値とし(b)を、また、 $f_i(X)$ を最大化したい場合は、 \hat{f}_i を予想される最大値より大きな値とし(c)を適用すればよい。なお、 $f_i(X)$ や $g_j(X)$ は、一般的には非線形関数であり、非線形目標計画法を用いることになるが、本研究では逐次線形化法によって解いている。

(2) 解析器としてのニューラルネットワーク

解析器としてのニューラルネットワークとは、設計変数に対して制約・目的関数及び感度係数を出力する機能を持ったネットワークを意味する。解析器は、設計変数と制約・目的関数の間に陽な数式関係がなくても、制約・目的関数の値が実験や観察など何らかの方法によって得られれば学習によって造ることができる。

a) 感度係数の計算方法

多目標最適化に目標計画法を適用しこれを逐次線形化法で解く場合には、設計変数の制約関数及び目的関数に対する感度係数の計算が必要となる。ここでは中間層が1つの3層のネットワークを対象に感度係数の計算方法を考える。いま、入力層、中間層、出力層のユニットを代表する添字を k, j, i ユニット出力を y_k, y_j, y_i ユ

ニット出力関数を F_j, F_i で表すと、式(1)、式(2)より出力とその偏微分は、中間層について

$$\begin{aligned} x_j &= \sum_k w_{jk} y_k, \quad y_j = F_j[x_j] \\ \partial y_j / \partial y_k &= (\partial F_j / \partial x_j) (\partial x_j / \partial y_k) \\ &= F'_j[x_j] w_{jk} \end{aligned} \quad (8)$$

出力層について

$$\begin{aligned} x_i &= \sum_j w_{ij} y_j, \quad y_i = F_i[x_i] \\ \partial y_i / \partial y_j &= (\partial F_i / \partial x_i) (\partial x_i / \partial y_j) \\ &= F'_i[x_i] \sum_j w_{ij} \end{aligned} \quad (9)$$

従って、出力 y_i の入力 y_k に関する感度係数は、

$$\partial y_i / \partial y_k = (\partial y_i / \partial x_i) (\partial x_i / \partial y_k) \quad (10)$$

上式に式(8)、式(9)の偏微分を代入し、

$$\partial y_i / \partial y_k = (F'_i[x_i] \sum_j w_{ij}) (F'_j[x_j] w_{jk}) \quad (11)$$

いま、 F_j, F_i を式(3)のシグモイド関数とすると、感度係数は、

$$\partial y_i / \partial y_k = [\epsilon y_i (1 - y_i) \sum_j w_{ij}] [\epsilon y_j (1 - y_j) w_{jk}] \quad (12)$$

となり、もしネットワークが学習済みとなればその計算は簡単に行える。

b) 多目標最適化問題

(1)の目標計画法を多目標最適化問題に応用し、制約関数 $g_j(X)$ と目的関数 $f_i(X)$ 及びそれらの感度係数の計算部分を、学習済みのネットワークで置き換えると、“解析器としてのニューラルネットワーク”を用いた多目標最適化となる。ネットワークの学習には一定の時間がかかるものの、一度学習済みとなったネットワークによる関数や感度係数の計算は、式(1)~式(2)の順伝播と式(12)の積和演算のみであるから最適化自体は極めて高速な計算となる。

(3) 最適化器としてのニューラルネットワーク

(2)で述べた解析器としてのニューラルネットワークは、以下に述べる最適化アルゴリズムを適用すれば、そのまま最適化器としてのニューラルネットワークとして利用できる。

a) 最適化アルゴリズム

従来の数理的最適化法を用いずに、ニューラルネットワークのみで多目標最適化を行う方法を考える。最適化アルゴリズムとは、学習済みネットワークにおいて、任意の入力値 $y_j^{(0)}$ ($j = 1, 2, \dots, N_0$) を入力層ユニットに与えた時、出力値 $y_i^{(M)}$ ($i = 1, 2, \dots, N_M$) が期待出力(目標値) d_i に等しくなる、あるいは d_i 以下(以上)

になるように入力値 $y_j^{(0)}$ を更新するアルゴリズムのことである。このアルゴリズムの基本的な考え方は、田中²¹⁾によって示されているが、ここでは目標計画法との比較を念頭に置いた形で示しておく。

(A) $y_i^{(M)} = d_i$ としたい場合

式(4)より出力層における誤差として、

$$\Delta y_i^{(M)} = \partial E / \partial y_i^{(M)} = y_i^{(M)} - d_i \quad (13)$$

を考える。出力層以外(第 m 層)の誤差は、

$$\begin{aligned} \Delta y_j^{(m)} &= \partial E / \partial y_j^{(m)} = \sum_{i=1}^{N_{m+1}} w_{ij}^{(m+1)} \Delta y_i^{(m+1)} \\ &\quad \epsilon y_i^{(m+1)} (1 - y_i^{(m+1)}) \end{aligned} \quad (14)$$

$$(m = M - 1, \dots, 1; j = 1, 2, \dots, N_m)$$

となり¹⁾、この式により誤差 $\Delta y_j^{(m)}$ を入力層方向へと伝播する。この時入力と出力の写像関係は保たれ、ネットワークの結合荷重 w_{ij} は固定されたままになる。出力層での誤差は逆方向の伝播のみを繰り返して入力層に至り、

$$\begin{aligned} \Delta y_j^{(0)} &= \partial E / \partial y_j^{(0)} \\ &= \sum_{i=1}^{N_1} w_{ij}^{(1)} \Delta y_i^{(1)} \epsilon y_i^{(1)} (1 - y_i^{(1)}) \end{aligned} \quad (15)$$

となる。入力層に伝播してきたこの $\Delta y_j^{(0)}$ を用いて入力値 $y_j^{(0)}$ を、

$$y_j^{(0)} \leftarrow y_j^{(0)} - \Delta y_j^{(0)} \quad (16)$$

と修正する。こうして修正された入力に対して、出力 $y_i^{(M)}$ を順伝播によって求め、新たな誤差 $\Delta y_j^{(0)}$ が0に近づくまでこの逆伝播と順伝播を繰り返す。

(B) $y_i^{(M)} \leq d_i$ としたい場合

基本的には(A)と同じで出力層の誤差として、

$$\Delta y_i^{(M)} = 0 \quad (y_i^{(M)} \leq d_i \text{ の時}) \quad (17)$$

$$\Delta y_i^{(M)} = y_i^{(M)} - d_i \quad (y_i^{(M)} > d_i \text{ の時}) \quad (18)$$

を定義してやればよい。

(C) $y_i^{(M)} \geq d_i$ としたい場合

同じく出力層の誤差として、

$$\Delta y_i^{(M)} = 0 \quad (y_i^{(M)} \geq d_i \text{ の時}) \quad (19)$$

$$\Delta y_i^{(M)} = y_i^{(M)} - d_i \quad (y_i^{(M)} < d_i \text{ の時}) \quad (20)$$

を定義してやればよい。

式(16)で修正されるのは、出力 $y_i^{(M)}$ に対してのみであるが、出力ユニットは N_M 個あり、全修正量は各出力からの修正量の総和をとり、

$$\Delta y_j^{(0)} = \sum_{i=1}^{N_M} \Delta y_{j,i} \quad (j = 1, 2, \dots, N_0) \quad (21)$$

となる。さらに式(21)は、各出力の重要度が対等の場合であるが、最適化では制約条件は目標より優先して

満足されなければならないし、多目標の最適化問題では、目標が競合しているので優先度を与えなければ意味のある最適解が定まらない。このような場合、制約および目標の達成の優先度を表す重み係数 w_i を導入して、誤差関数を、

$$E = \frac{1}{2} \sum_{i=1}^{N_M} w_i (y_i^{(M)} - d_i)^2 \quad (22)$$

とし、出力層の誤差を式(13)の代わりに、

$$\Delta y_i^{(M)} = \partial E / \partial y_i^{(M)} = w_i (y_i^{(M)} - d_i) \quad (23)$$

とすることで優先度に対応できる。なお、以上のような入力値の修正が可能なのは、連続値のみであるから、設計変数は連続値でなければならない。

b) 多目標最適化問題

目標計画法において、 $f_i(X)$ と \hat{f}_i の間の差異 d_i^+ , d_i^- が、目標に応じて最小になるように設計変数を決めることと、ニューラルネットワークにおいて、出力値 $y_i^{(M)}$ と期待出力 d_i の間の差異が目標に応じて最小になるように入力値 $y_j^{(0)}$ を決めることは、一対一に対応する。従って、ネットワークが学習済みであれば、目標計画法を用いずに“最適化器としてのニューラルネットワーク”のみで多目標最適化を行うことが可能となる。なお、(1)で述べた(a),(b),(c)の目標の各タイプに対しては上の(A),(B),(C)の各々が対応し、 $f_i(X)$ を $y_i^{(M)}$ に、 \hat{f}_i を d_i に置き換えて考えればよい。

(4) 異なる設計条件に対応した最適化器としてのニューラルネットワーク

ここで用いるネットワークの入力層ユニットは、設計条件と設計変数に割り当てられる。設計条件とは構造設計におけるスパン長や構造物の高さ、弾性係数などに該当するものである。これらは最適化の過程で変化しないので離散値や定性的データであってもよい。いま、ある一定の数の設計条件の組み合わせに対して、やはりある一定の数の設計変数と制約・目的関数のペアを学習データとして準備し、ネットワークに学習させると、この学習済みネットワークは次のような利用方法が可能となる。

『所定の設計条件及び設計変数の初期値を入力層ユニットに、目標値を出力層ユニットに与え(3)で述べた最適化を行う。式(16)の修正を設計変数のみについて行えば、所定の設計条件における最適化が可能になる。』

(以上の4種類の最適化手法(1)~(4)を比較のため、まとめて図-3に示す。)

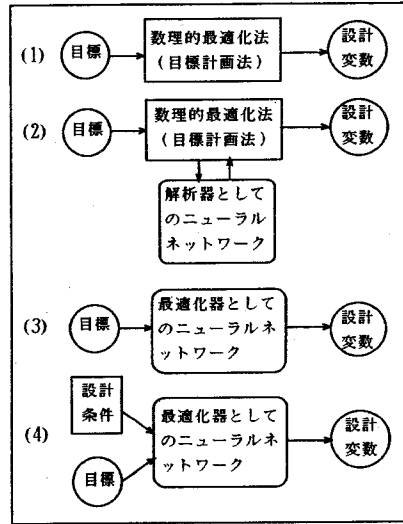


図-3 最適化手法の種類




図-4 計算例トラス

表-1 理想点と最悪点

設計目標	座屈荷重係数 B	重量 $W(\text{kg})$
理想点	7.966	3184
最悪点	2.744	4910

4. トラスの多目標最適設計への応用

(1) 計算例トラス

3.で述べた最適化手法を図-4に示したトラスの多目標最適設計に適用する。このトラスの設計変数は5グループにまとめた部材断面積 $X = \{x_1, x_2, \dots, x_5\}$ である(断面は正方形箱型断面)。部材断面積の範囲は $25\text{cm}^2 \sim 45\text{cm}^2$ とし、材料は鋼材を想定している。制約条件は先端の水平変位 $D(X)$ について $D(X) \leq D_a$ (D_a は許容変位)とする。また、目的関数は面内全体座屈荷重係数 $B(X)$ と重量 $W(X)$ を考え多目標問題とする。 $D(X) \leq D_a (=0.8\text{cm})$ とした時の $B(X)$ と $W(X)$ の理想点と最悪点を表-1に示す。 $B(X)$ は大きくするこ

と、 $W(X)$ は小さくすることが望ましい目標である。

この計算例は従来法によって十分対処のできる例ではあるが、ニューラルネットワークの応用方法を具体的に示し、特にニューラルネットワークを応用した最適化法が、従来の数理的最適化法に代わり得ることを示すために用いられている。

(2) 目標計画法による定式化

トラスの多目標最適設計に、3.の(1)で述べた目標計画法を適用する。達成関数の表し方は設計目標の決め方と目標達成の優先順位によって変わるが、とりあえず目標は、 $B(X) \geq \hat{B}, W(X) \leq \hat{W}$ 優先順位は、 $B(X), W(X)$ の順であることを想定して示しておく。 \hat{B}, \hat{W} は $B(X), W(X)$ の目標値である。式(7)に従って目標計画法による設計問題の定式化を試みると以下の通りである。

find $X = \{x_1, x_2, \dots, x_5\}$ to minimize

$$A = [(d_1^+), (d_2^-), (d_3^+)] \quad (24)$$

subject to

$$\begin{aligned} D(X) - d_1^+ + d_1^- &= D_a \\ B(X) - d_2^+ + d_2^- &= \hat{B} \\ W(X) - d_3^+ + d_3^- &= \hat{W} \\ d_i^+ \cdot d_i^- &= 0, d_i^+ \geq 0, d_i^- \geq 0 \quad (i = 1, 2, 3) \\ x_{min} \leq x_n \leq x_{max} \quad (n = 1, 2, \dots, 5) \end{aligned}$$

(3) ニューラルネットワークの学習

まず解析器として用いられるニューラルネットワークの学習について一般的な知見を示しておく。ここでのネットワークの入力層ユニットは5個で設計変数 $\{x_1, x_2, \dots, x_5\}$ に割り当てられ、出力層ユニットは3個で制約・目的関数 ($D(X), B(X), W(X)$) に割り当てられる。

a) 学習データとテストデータの準備

ネットワークの学習のために次の3ケースのデータを準備する。

[D-1]: 部材断面積を 25,30,35,40,45 cm^2 と変えると5種の部材で3125通りの組み合わせができるが、ここからランダムに50個の組み合わせを選んで入力データとする。

[D-2]: 同じく100個の組み合わせを選んだもの。

[D-3]: 同じく150個の組み合わせを選んだもの。

以上の3ケースの入力データに対して、各々対応する出力データ $D(X), B(X), W(X)$ を計算して学習データを準備する。また、部材断面積を 30,40 cm^2 と変えると、5種の部材で32通りの入力データができるが、これも対応する関数値を求めておき、ネットワークのテストデータとする。

表-2 ネットワークの学習と推定精度

ネットワーク	学習データ	繰返し回数	学習時間(分)	推定精度 ($\times 10^{-3}$)	収束状況
N-1	D-1	2050	1.6	21.4	B(X)が25000回打切 B(X)が25000回打切
	D-2	8810	12.8	8.7	
	D-3	8614	19.3	8.5	
N-2	D-1	1789	2.5	23.4	
	D-2	4077	11.4	11.1	
	D-3	3516	14.8	7.1	
N-3	D-1	3971	2.0	16.7	25000回打切
	D-2	22585	22.7	3.7	
	D-3	25000	37.5	4.9	
N-4	D-1	2125	1.8	11.7	
	D-2	4968	8.2	6.0	
	D-3	7314	18.1	3.2	

b) ネットワークのトポロジーと学習データ数

ネットワークのトポロジーとして次の4ケースを考えその性能の比較を行う。中間層の数は1つで一定とし、そのユニットの数は、概ね入力と出力のユニットの合計に等しい数の場合とその2倍の数の場合を試みた。

[N-1]: 1出力モジュールを3つ並列的に使用する。各モジュールの構造は入力層5、中間層5、出力層1ユニットで共通とする。これを $N(5-5-1) \times 3$ と表す。

[N-2]: 同じく1出力モジュール型で、 $N(5-10-1) \times 3$ とする。

[N-3]: 3出力を一体とし中間層を8ユニットとした一体型で、 $N(5-8-3) \times 1$ と表す。

[N-4]: 同じく一体型で、 $N(5-14-3) \times 1$ とする。

上の4ケースのネットワークにおいて、a)で述べた3種類の学習データによって学習を行い、さらに共通のテストデータによって精度のテストを行った結果を表-2に示す。なお、学習パラメータ η, α, ϵ は各ケースで同一とし、各々 0.6, 0.8, 1.0 とした。学習の終了は、モジュール型では1出力ごとに全学習データの出力誤差の2乗平均が制限値 0.0001 以下になった時とした。また、一体型では3出力の内、最悪の出力誤差の2乗平均が制限値 0.0001 以下になった時とした。ただし、25000回の繰り返しによっても誤差が制限値以下にならない時は計算を打ち切った。表-2においてモジュール型の繰返し回数と推定精度は3モジュールの平均で示してある。

表-2から得られる学習に関する知見は次の通りである。

- [N-1]での[D-2]と[D-3]の $B(X)$ に対応するモジュール2、及び[N-3]での[D-3]が、25000回でも収束していない。これは中間層のユニットが不足しているためである。
- 学習データの数が多ほど収束までの時間はかかるが、精度のよいネットワークが得られる。しかし[D-2]と[D-3]では大差はない。
- 学習の終了条件により、一体型の方がやや精度は

表-3 学習の誤差制限と推定精度

ネットワーク	学習データ	誤差の制限値	繰返し回数	学習時間(分)	推定精度($\times 10^{-4}$)
N-2	D-2	C-1	17563	49.0	7.6
		C-2	4077	11.4	11.1
		C-3	2251	2.1	17.1

表-4 関数値と感度係数についての比較の一例

設計変数 $x_1 \sim x_5 = 35\text{cm}^2$					
D(cm)	$\partial B/\partial x_1$	$\partial D/\partial x_1$	$\partial W/\partial x_1$	$\partial B/\partial x_2$	$\partial D/\partial x_2$
0.804	0.0099	0.0093	0.0014	0.0012	0.0015
0.799	0.0094	0.0092	0.0015	0.0013	0.0014
B	$\partial B/\partial x_1$	$\partial B/\partial x_2$	$\partial B/\partial x_3$	$\partial B/\partial x_4$	$\partial B/\partial x_5$
3.717	0.0131	0.1372	0.0622	0.0048	0.0763
3.756	0.0096	0.1327	0.0778	0.0068	0.0939
W(kg)	$\partial W/\partial x_1$	$\partial W/\partial x_2$	$\partial W/\partial x_3$	$\partial W/\partial x_4$	$\partial W/\partial x_5$
3786	2226	2483	2428	3506	3533
3819	2400	2400	2400	3394	3394

よいが、繰返し回数や学習時間については、はっきりしたことはいえない。

c) 誤差の制限値と出力の精度

本例題のように定量的な写像を利用して最適設計を行う場合には、出力の精度を確保することは重要である。そこで、ネットワーク [N-2] において [D-2] を用い、誤差の制限値を 0.00005 [C-1], 0.0001 [C-2], 0.0002 [C-3] と変えて学習とテストを行った。結果は表-3 に示すが当然のことながら誤差の制限値をきつくすれば、学習時間は増大し、一方、出力の精度は向上する。なお、表-4 は誤差制限が 0.00005 の時の関数値と感度係数を理論値と比較して示した一例である。上段がネットワークの出力値、下段が理論値である。両者の比較から分かるように感度係数は関数値に比べて精度がやや劣る。

d) 解析器に用いるニューラルネットワーク

b)~c)の結果から解析器として、ネットワーク [N-2] で学習データ [D-2] を誤差の制限値 0.00005 [C-1] で学習した学習済みネットワークを用いるものとする。モジュール型を用いるのは、制約・目的関数の追加・削除の可能性を考慮したためである。

(4) 解析器としてのニューラルネットワーク

目標計画法によるトラスの多目標最適設計 ([M-1] とする) から解析器部分を除き、代わりに (3) の d) で述べた学習済みネットワークを組み込む。この多目標最適設計を [P-1] とし、[M-1] と [P-1] によって以下の4ケースの多目標最適設計を試みる。

- (a) $W(X)$ の優先的な最小化, $B(X)$ は無視
- (b) $W(X) \leq \hat{W}(=4000\text{kg})$ とし次に $B(X)$ の最大化

表-5 最適設計の結果

ケース	制約・目的関数			設計変数(cm^2)				
	D(cm)	B	W(kg)	x_1	x_2	x_3	x_4	x_5
(a) [P-1]	0.800	2.563	3167	38.2	36.4	25.0	25.0	25.0
	[M-1]	0.800	2.744	3184	37.5	36.9	25.0	25.0
(b) [P-1]	0.679	6.564	4000	41.3	44.7	45.0	25.9	32.3
	[M-1]	0.751	5.752	4000	34.7	40.9	45.0	28.1
(c) [P-1]	0.694	5.997	3830	39.9	44.9	44.2	25.4	28.1
	[M-1]	0.718	6.003	3883	36.4	45.0	45.0	30.0
(d) [P-1]	0.705	5.000	4500	44.1	35.3	39.5	45.0	41.3
	[M-1]	0.707	5.004	4500	44.0	35.0	36.9	44.3

表-6 最適設計の結果

ケース	制約・目的関数			設計変数(cm^2)					
	D(cm)	B	W(kg)	x_1	x_2	x_3	x_4	x_5	
(a) 重みw	0.5	0.01	0.1						
	[P-2]	0.813	2.288	3081	37.5	36.3	22.5	24.6	24.2
	[M-1]	0.800	2.744	3184	37.5	36.9	25.0	25.0	25.0
(b) 重みw	0.5	0.01	0.1						
	[P-2]	0.704	6.616	4050	37.2	45.0	44.7	30.7	32.9
	[M-1]	0.751	5.752	4000	34.7	40.9	45.0	28.1	37.7
(c) 重みw	0.5	0.1	0.1						
	[P-2]	0.720	5.654	3743	37.4	44.3	43.5	26.4	26.9
	[M-1]	0.718	6.003	3883	36.4	45.0	45.0	30.0	27.4
(d) 重みw	0.5	0.1	0.1						
	[P-2]	0.706	5.053	4469	42.5	36.4	39.3	45.0	40.7
	[M-1]	0.707	5.004	4500	44.0	35.0	36.9	44.3	43.7

(c) $B(X) \geq \hat{B}(=6.00)$ とし次に $W(X)$ の最小化

(d) 優先度同等で $B(X) = \hat{B}(=5.00)$ と $W(X) = \hat{W}(=4500\text{kg})$ を達成

表-5に上の4ケースの設計の結果を示す。上段が本方法 [P-1] による結果、下段が目標計画法 [M-1] による結果である。両者の結果を比較すると、設計変数の値には差が出ているが、制約・目的関数には殆ど差がなく、解析器としてのニューラルネットワークの有効性が分かる。[P-1] は [M-1] より計算時間が約8分の1と短くなるが、学習データの作成や学習にかかる時間を考慮すれば、計算時間の点で [P-1] が [M-1] より優れているとはいえない。

(5) 最適化器としてのニューラルネットワーク

次に、目標計画法の代わりに最適化器としてのニューラルネットワークを用いた最適設計 ([P-2] とする) を行う。計算例は (4) の場合と同じである。最適化の場合には5個の設計変数に対する上下限の制約条件10個が必要になり、この部分はモジュール型のネットワーク $N(5-14-10) \times 1$ として独立に学習する。これは入力された設計変数と同じ値を2個ずつ出力するネットワークである。データ数は100個、学習パラメータ η, α, ϵ は 0.6, 0.7, 0.8 誤差の制限値は、0.0001 とし学習した。このネットワークと (3) の d) で述べたネットワーク [N-2] を並列すれば最適化用のネットワークとなる。

表-6に目標達成の優先度を与える重み係数とともに設計結果を示す。設計変数の上下限に対する制約の重み係数は1.0である。表-6の各行の上段が本方法[P-2]による結果、下段が目標計画法[M-1]による結果である。両者の結果を比較するとやはり結果に大きな差はない。すなわち、ニューラルネットワークを目標計画法の代りに最適化手法として用いることができるといえる。最適化計算に影響を及ぼす要因として、ネットワークの学習精度、設計変数の初期値、収束条件、重み係数などが挙げられる。この中では重み係数の影響が大きく、この値が目標達成の優先度に対応して適切に与えられていないと目標とした解に収束しないことがある。重み係数の決定にはある程度の試行錯誤が必要であるが、この決定問題は多目標最適化に特有の問題である。なお、[P-2]は[M-1]に比べて計算時間が約12分の1となるが、(4)の場合と同じ理由で計算時間上の優劣は論じられない。

(6) 異なる設計条件に対応した最適化器としてのニューラルネットワーク

a) ニューラルネットワークのトポロジー

図-4のトラスにおいて、設計変数と制約関数・目的関数を前例と同じとしたまま、トラス全体の長さ L と高さ H を設計条件とみなすことにする。この L と H を入力するユニットを入力層に加えて7ユニットとし、中間層のユニットを12としたモジュール型ネットワーク $N(7-12-1) \times 3$ を準備する。

b) 学習データの準備と学習

長さ L について、20m,24m,28m 高さ H について、5m,6m,7mと変化させ、 L と H の9通りの組み合わせについて、設計変数と制約・目的関数のペアをランダムに40組ずつ準備すると学習データ数は全部で360個となる。学習は、学習パラメータ η, α, ϵ を0.6,0.8,1.0とし、誤差制限を0.00005として行った結果、計算時間約40分で学習済みとなった。

c) 異なる設計条件に対応した最適設計

この場合も5個の設計変数に対する上下限の制約条件10個が必要になり、この部分はモジュール型のネットワーク $N(7-14-10) \times 1$ として独立に学習する。このネットワークとb)で造られたネットワークを並列して最適化用のネットワークとする。

長さ L と高さ H の組み合わせは3通り考え、各々について(4)のケース(b)と(c)について最適設計を行った。重み係数の与え方は、(5)の場合と同じである。表-7に結果を示すが、上段の[P-3]はニューラルネットワークによる結果、下段の[M-2]は目標計画法による結果である。両者を比べるとやはり大きな差はなく、所定の設計条件 L と H に対して、目標計画法の結果に近い

表-7 最適設計の結果

設計条件	ケース	制約・目的関数			設計変数(cm ²)				
		D(cm)	B	W(kg)	x_1	x_2	x_3	x_4	x_5
L= 22m H= 5.5m	(b)[P-3]	0.618	8.487	3725	38.5	45.0	44.6	35.6	43.1
	[M-2]	0.636	8.475	4000	37.7	43.6	45.0	31.9	43.6
	(c)[P-3]	0.703	5.925	3186	33.4	41.6	38.1	25.4	38.5
	[M-2]	0.693	5.972	3396	36.4	40.7	42.3	25.0	30.8
L= 24m H= 6.0m	(b)[P-3]	0.683	6.834	4032	38.4	45.0	42.3	36.1	41.4
	[M-2]	0.751	5.752	4000	34.7	40.9	45.0	28.1	37.7
	(c)[P-3]	0.733	5.869	3593	35.2	44.6	40.2	25.0	39.5
	[M-2]	0.718	6.003	3883	36.4	45.0	45.0	30.0	27.4
L= 26m H= 6.5m	(b)[P-3]	0.753	5.691	4082	39.6	45.0	42.8	25.0	39.2
	[M-2]	0.788	4.593	4000	36.8	44.7	45.0	25.0	25.0
	(c)[P-3]	0.761	5.688	4075	38.6	45.0	42.7	25.0	40.5
	[M-2]	0.758	5.966	4652	36.1	45.0	45.0	32.4	39.9

結果が得られている。このように未学習の設計条件においても正しい最適解を迅速に得ることができる点は、ニューラルネットワークの有用性を示すものである。

5. コンクリートの配合最適設計への応用

(1) 鋼繊維補強コンクリートの配合最適設計問題

次に、より一般的な多目標最適化の例として、鋼繊維補強コンクリートの配合最適設計を取り上げる。この例では、4.の[M-1]、[M-2]に相当する最適化は不可能であるが、[P-1]、[P-2]、[P-3]に相当する最適化は可能である。

鋼繊維補強コンクリートでは、数パーセント(体積)の鋼繊維の混入によって、曲げ強度や引張強度が著しく改善されるが、ワーカビリティが悪くなったり、コストが高くなるなどの欠点もある。この配合設計問題における設計条件を使用粗骨材の最大寸法 G_m と混入率 G_v (体積)、設計変数を単位水量 W と繊維混入率 F とする。また、目的関数を、まだ固まらないコンクリートのスランプ S と硬化後28日曲げ強度 σ とし、目標のスランプと曲げ強度が与えられた時に、使用材料の各量を決定することを配合最適設計とする。最大寸法は離散値をとるのでデジタルユニット3個を当て、残りの5つは連続値をとるのでアナログユニットを当てる。ただし、スランプは連続値と考えた場合と、「小」、「中」、「大」の定性的データと考えた場合の両方を検討し、定性的データとした場合はデジタルユニット3個が当てられる。スランプ「小」は6cm以下、「中」は6cmより大きく12cm以下、「大」は12cmより大きい場合としている。

この場合は比較のために連続値を定性的表現に変えたにすぎないが、例えばワーカビリティのように「良い」、「普通」、「悪い」などと定性的に表現することが妥当な要因や判断基準は色々あり、それらをそのまま設計条件や目的関数に取り入れることができるのはニュー

表-8 シミュレーション用データ




図-5 ネットワーク [N-3]

ラルネットワークの長所である。なお、曲げ強度を大きくするという目標とスランプを大きくするという目標は競合関係にあり多目標最適化問題となる。

また、4.で述べた構造最適設計との主な違いは以下の通りである。

- データは実験値であり、設計変数と目的関数の関係が数式によって陽に表せない。
- 実験データであるので学習データの数が限られている。
- データには必ず誤差が含まれているので、過学習とならないように注意する必要がある。
- 離散値をとる設計条件や、定性的データとなる目的関数が含まれている。

ただし、一度ネットワークが構築できれば、これを解析器や最適化器として用い、構造最適設計の場合と同様の最適化が可能になる。

(2) ニューラルネットワークの学習

a) ニューラルネットワークのトポロジー

ネットワークのトポロジーとしてつぎの3ケースを考える。

- [N-1]: 入力を W と F の2個、出力を S と σ の2個としたモジュール型ネットワーク $N(2-6-1) \times 2$
- [N-2]: 入力を G_m と G_v (設計条件), W と F とするが、 G_m には3個のデジタルユニットを与えて合計6個、出力を S と σ の2個としたモジュール型ネットワーク $N(6-9-1) \times 2$
- [N-3]: 図-5に示すように、入力は [N-2] と同じとし、定性的データとした出力のスランプ S に3個のデジタルユニットを与えて、 σ とともに合計4個としたモジュール型ネットワーク $N(6-12-3) \times 1$ と $N(6-12-1) \times 1$

	$Gv=20\%$				$Gv=30\%$			
	W (kg)	F (%)	S (cm)	σ (kgf/cm ²)	W (kg)	F (%)	S (cm)	σ (kgf/cm ²)
$G_m=15mm$	* 202	0.0	7.6	36	* 178	0.0	7.3	35
	202	0.5	5.5	44	178	0.5	5.3	43
	* 202	1.0	3.5	58	* 178	1.0	2.5	57
	* 202	1.5	1.4	71	* 178	1.5	1.0	66
	210	0.0	12.0	36	186	0.0	10.7	34
	* 210	0.5	10.4	43	* 186	0.5	8.2	42
	* 210	1.0	7.2	56	* 186	1.0	6.4	54
	210	1.5	4.7	68	* 186	1.5	4.0	62
	218	0.0	17.0	35	194	0.0	15.2	33
	* 218	0.5	15.5	42	194	0.5	13.5	41
	218	1.0	13.0	54	* 194	1.0	11.4	53
	218	1.5	10.2	64	194	1.5	9.1	59
$G_m=25mm$	* 203	0.0	8.5	33	182	0.0	8.1	31
	203	0.5	6.2	40	182	0.5	5.7	38
	* 203	1.0	4.0	51	* 182	1.0	3.5	48
	203	1.5	2.2	59	* 182	1.5	2.0	57
	212	0.0	12.7	32	* 190	0.0	12.3	29
	212	0.5	10.5	38	190	0.5	9.1	37
	* 212	1.0	7.8	49	* 190	1.0	6.1	46
	* 212	1.5	5.2	55	* 190	1.5	4.6	54
	222	0.0	17.5	30	* 199	0.0	16.0	28
	222	0.5	15.8	37	199	0.5	14.4	35
	* 222	1.0	13.5	45	* 199	1.0	12.5	43
	222	1.5	11.2	53	199	1.5	10.0	52
$G_m=40mm$	206	0.0	8.9	30	* 185	0.0	8.5	29
	* 206	0.5	6.6	38	185	0.5	6.2	37
	206	1.0	4.8	45	185	1.0	4.5	45
	* 206	1.5	3.0	53	185	1.5	2.6	52
	215	0.0	13.1	28	* 194	0.0	11.7	27
	* 215	0.5	9.7	36	194	0.5	9.3	35
	215	1.0	7.6	44	* 194	1.0	6.5	43
	215	1.5	5.5	52	194	1.5	5.0	49
	* 225	0.0	18.0	28	* 204	0.0	17.7	27
	225	0.5	16.1	35	204	0.5	15.5	33
	* 225	1.0	14.0	43	* 204	1.0	13.4	41
	225	1.5	11.8	48	204	1.5	10.8	47

b) 学習データの準備

学習データとして、著者の一人が以前に行った繊維補強コンクリート(水セメント比は45%で一定)に関する実験の結果²³⁾を参考にして造ったシミュレーション用のデータを用いる。粗骨材の最大寸法 G_m は3種類(15,25,40mm)、混入率 G_v は2種類(20,30%)とし、その6通りの組合せに対して単位水量 W を3種類(G_m と G_v によって異なる)、繊維混入率 F を4種類(0,0.5,1.0,1.5%)考え、スランプ S と曲げ強度 σ を与えている。データ数は全部で72個となるが、表-8に全データを示しておく。

c) ニューラルネットワークの学習

[N-1]の学習

$G_m=15mm, G_v=20\%$ の時のデータ12個を学習データとして用い、学習パラメータ η, α, ϵ を0.4, 0.8, 1.0 誤差制限を0.001として学習を行った。学習時間は1秒未満である。

[N-2]の学習

まず、全データ72個を学習データとして用い、学習パラメータ η, α, ϵ を0.4, 0.8, 1.0 誤差制限を0.001, 0.0001として学習を行った。学習時間は誤差制限が0.001の時4秒, 0.0001の時8分である。次に、学習データ数を48, 36, 24, 12個と減らして学習を行い、学習後72個の




図-6 学習データ数と誤差の2乗平均との関係

データについて目的関数の推定を行ってみた。図-6に、データ数と実験値(期待出力)と推定値の誤差の2乗平均との関係を示す。図-6より学習に必要なデータ数は24~36個で十分であることが分かる。このことは72ケースのうち24~36ケースを選んで実験を行えば72ケースの実験を行った結果と同じ結果が得られることを意味する。ただし、どの程度データを減らせるかは非線形性の程度による。なお、個数を減らす場合、72個のデータからランダムにデータを減らしていくが、減らすデータに片寄りがないようにする。次に、表-8において*印のついた36個のデータによる学習結果を図-7、図-8に示す。この図のデータの分布と相関係数 r の値より、誤差制限は0.001で十分であると判断する。実際、誤差制限を0.0001とした学習では過学習状態になり、かえって目的関数の推定に不適当なネットワークとなる。従って後の最適化では、36個の学習データを誤差制限0.001で学習したネットワークを [N-2] として用いていく。

[N-3] の学習

スランプ評価を定性的データに変えた36個のデータを用いて、学習パラメータ η, α, ϵ を0.8, 0.9, 1.2 誤差制限を0.001として学習を行った。学習時間は76秒である。学習後残りの36個のデータについてスランプの推定を行った結果を表-9に示しておく。表-9より実験値のランクとニューラルネットワークによる推定ランクとが一致したデータ数は26個で、不一致が10個となっていることが分かる。なお、不一致となったデータのスランプはすべてランクの境界値に近い値になっている。




図-7 学習の結果(スランプ)




図-8 学習の結果(曲げ強度)

表-9 スランプ推定の結果

		実際のスランプ		
		小	中	大
ネットワークによるスランプ推定	小	5	1	0
	中	6	13	2
	大	0	1	8

(3) 解析器及び最適化器としてのニューラルネットワーク

$Gm=15mm$, $Gv=20\%$ の時の入力 W , F と出力 S , σ の関係はネットワーク [N-1] で学習済みであるのでこれを用いて最適化ができる。すなわち、目標としてスランプ S と曲げ強度 σ が与えられれば、それを実現する単位水量 W と繊維混入率 F が決定できる。方法は2通りあり、1つは4.の [P-1] に相当する方法 ([Q-1] と

表-10 コンクリート配合の最適化

ケース	設計目標		設計結果			
			目的関数		設計変数	
	S(cm)	σ (kgf/cm ²)	S(cm)	σ (kgf/cm ²)	W(kg)	F(%)
(a)[Q-1] [Q-2]	5.0	60	5.0	60	206	1.1
	5.0	60	5.0	60	205	1.1
(b)[Q-1] [Q-2]	10.0	60	10.0	60	216	1.2
	10.0	60	10.0	60	216	1.2
(c)[Q-1] [Q-2]	15.0	60	15.0	60	225	1.3
	15.0	60	14.7	60	226	1.3
(d)[Q-1] [Q-2]	10.0	45	10.0	45	209	0.5
	10.0	45	10.0	46	209	0.5
(e)[Q-1] [Q-2]	10.0	30	10.0	45	209	0.5
	10.0	30	10.8	43	210	0.4

表-12 コンクリート配合の最適化

ケース	設計目標		設計結果			
			目的関数		設計変数	
	S(cm)	σ (kgf/cm ²)	S(cm)	σ (kgf/cm ²)	W(kg)	F(%)
(a)[Q-4] [Q-1]	小	60	小	60	202	1.0
	5.0	60	5.0	60	206	1.1
(b)[Q-4] [Q-1]	中	60	中	60	214	1.1
	10.0	60	10.0	60	216	1.2
(c)[Q-4] [Q-1]	大	60	大	60	226	1.4
	15.0	60	15.0	60	225	1.3
(d)[Q-4] [Q-1]	中	45	中	46	211	0.5
	10.0	45	10.0	45	209	0.5
(e)[Q-4] [Q-1]	中	30	大	39	230	0.4
	10.0	30	10.0	45	209	0.5

表-11 コンクリート配合の最適化 [Q-3]

設計条件	ケース	設計目標		設計結果			
				目的関数		設計変数	
		S(cm)	σ (kgf/cm ²)	S(cm)	σ (kgf/cm ²)	W(kg)	F(%)
G _m =15mm G _v =20%	(b)	10.0	60	10.0	60	214	1.2
	(c)	15.0	60	15.0	60	224	1.2
G _m =15mm G _v =30%	(b)	10.0	60	10.0	60	194	1.3
	(c)	15.0	60	14.9	60	203	1.3
G _m =25mm G _v =20%	(b)	10.0	60	10.0	58	221	1.6
	(c)	15.0	60	14.0	58	228	1.6
G _m =25mm G _v =30%	(b)	10.0	60	9.9	56	201	1.6
	(c)	15.0	60	12.6	55	206	1.5
G _m =40mm G _v =20%	(b)	10.0	60	9.9	54	226	1.6
	(c)	15.0	60	13.0	54	231	1.6
G _m =40mm G _v =30%	(b)	10.0	60	9.8	52	204	1.6
	(c)	15.0	60	11.7	51	207	1.6

する)であり、もう1つは[P-2]に相当する方法([Q-2]とする)である。[Q-1]は、目標計画法の解析器部分にネットワーク[N-1]を解析器として組み込んだものであり、一方[Q-2]は、目標計画法を用いず、ネットワーク[N-1]を最適化器として用いるものである。[Q-1]は、[Q-2]の結果を検証するために実行する。[Q-2]の場合には、設計変数 W と F に対する上下限の制約条件4個が必要となる。この部分のネットワークは N(2-6-4)とし、学習データ数72個、学習パラメータ η, α, ϵ を0.4, 0.8, 1.0 誤差制限を0.0001で学習を行った。設計目標の優先度は同等とし、 $200\text{kg} \leq W \leq 225\text{kg}$ 、 $0.5\% \leq F \leq 1.5\%$ の制約をつけて、5ケースの最適設計を行った。結果は表-10に示すが、[Q-1]と[Q-2]で殆ど同じ結果が得られている。斜体で示された設計変数は、上限または下限に達しているものである。ケース(c)では W が上限に達してスランプが不達成となっており、ケース(e)では F が下限に達して曲げ強度が不達成となっている。

(4) 異なる設計条件に対応した最適化器としてのニューラルネットワーク

この場合の最適化とは、設計条件である粗骨材の最大寸法 G_m と混入率 G_v の所定の値に対して、目標と

したスランプ S と曲げ強度 σ を与える単位水量 W と繊維混入率 F を決定することである。 W と F に対する上下限の制約条件のネットワークは N(6-9-4)とし、学習データ数72個、学習パラメータ η, α, ϵ を0.4, 0.8, 1.0 誤差制限を0.0001で学習を行った。

a) スランプを連続値とした場合

ネットワーク[N-2]と制約条件用のネットワークを並列して最適化用のネットワークとする。設計条件の組み合わせ6通りの各々について(3)の設計目標(b)と(c)について最適設計([Q-3]とする)を行った。この最適設計は4.の[P-3]に相当する。制約は、 $200\text{kg} \leq W \leq 225\text{kg}$ ($G_v = 20\%$ の時)、 $175\text{kg} \leq W \leq 205\text{kg}$ ($G_v = 30\%$ の時)、 $0.5\% \leq F \leq 1.5\%$ (共通)である。結果は表-11に示すが、 G_m が大きくなるにつれて、また G_v が20%より30%の方が目標の達成が困難になっている。4.のトラスの最適設計の場合と異なり、結果の正しさを検証することはできないが、全体的に見れば妥当な結果であるといえる。

b) スランプを定性的データとした場合

ネットワーク[N-3]と制約条件用のネットワークを並列して最適化用のネットワークとする。設計条件を $G_m = 15\text{mm}$ 、 $G_v = 20\%$ とし(3)における設計目標のスランプを、(a)は「小」、(b),(d),(e)は「中」、(c)は「大」と変えて最適設計([Q-4]とする)を行った。結果は表-12に示すが、[Q-1]との比較より妥当な結果である。ケース(e)は設計目標のスランプが得られていないが、曲げ強度は[Q-1]より目標に近くなっている。以上から、目標が定性的なものであっても、方法的には連続値の場合と全く同じように最適化ができるといえる。

6. あとがき

本研究では、多目標最適化手法へのニューラルネットワークの応用を試みた。その結果、明らかになったことは以下の通りである。

(a) トラスの多目標最適設計より

- ニューラルネットワークを解析器として応用した場合 ([P-1]) は、最適化に従来型の数理的最適化法を必要とするので、そのメリットは小さい。
- 最適化器として応用した場合 ([P-2]) は、最適化に従来法を必要とせず、従来法に比べて極めて簡単な理論・アルゴリズム・計算プログラムによって最適化が可能である。
- また、設計条件を入力に含めた最適化器の場合 ([P-3]) は、設計条件の変更に迅速に対応した最適化が可能になる。
- 最適解の精度は従来法に比べて劣るが、学習条件の工夫によって、より解析精度の高いネットワークの構築が可能であり、そのことによって解析と最適化の精度を上げることが可能である。
- 本研究ではデジタルコンピュータによってニューラルネットワークの学習を行っているため、学習のための時間によって、ニューラルネットワークの有用性が相殺されている感が強いが、この点はニューロコンピュータの普及によって解決されると考えられる。

(b) コンクリートの配合最適設計より

- 実験データより解析器としてのネットワークが構築できれば、これを従来型の数理的最適化法に組み込んで最適化ができる ([Q-1])。解析器 (写像関係) はニューラルネットワーク以外の方法によって構築してもよいが、多入力-多出力の場合にはニューラルネットワークが有利である。
- 解析器としてのネットワークはそのまま最適化器として応用できる ([Q-2]) のでわざわざ従来法を用いる必要はなく、ニューラルネットワークだけで最適化を行うのが自然である。出力に定性的データが含まれている場合には従来法では対応が難しいが、ニューラルネットワークによれば簡単に対応できる。
- 設計条件に離散値を割り当てたり ([Q-3])、目的関数に定性的データを割り当てても ([Q-4]) 最適化が可能である。すなわち、最適化手法におけるニューラルネットワークの有効性と汎用性は、構造最適設計よりもこのような応用例において明らかになる。なお、離散値や定性的データを設計変数とすることはできず、このことは本最適化手法の欠点の一つとなっている。

- 4) 島崎敏一, 安田誠一: ニューラルネットワークによる交通手段選択モデル, 土木学会論文集, 第 494 号/IV-24, pp.79-86, 1994.
- 5) 古田均, 大谷裕生, 白石成人: ニューラルネットワークの補修工法選定への応用, 構造工学における数値解析法シンポジウム論文集, 第 14 巻, pp.339-344, 1990.
- 6) 三上市蔵, 田中成典, 倉地晶: 鋼橋疲労損傷の補修方法選定のための学習機能のあるニューラルネットワークシステム, 構造工学論文集, Vol.37A, pp.655-668, 1991.
- 7) 三上市蔵, 平田卓也, 神戸和仁: 鋼プレートガーダー橋損傷部位予測へのニューラルネットワークの適用, 構造工学における数値解析法シンポジウム論文集, 第 17 巻, pp.25-30, 1993.
- 8) 安田登, 白木渡, 松島学, 堤知明: ニューラルネットワークによるコンクリート構造物の劣化評価, コンクリート工学年次論文報告集, Vol.15, No.1, pp.847-852, 1993.
- 9) 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, 第 496 号/V-24, pp.41-49, 1994.
- 10) 古田均, 大谷裕生, 中林正司, 白石成人: ニューラルネットワークの橋梁景観設計への応用, 構造工学論文集, Vol.37A, pp.669-675, 1991.
- 11) 白木渡, 松保重之, 高岡宣善: ニューラルネットワークによるアーチ橋の景観評価システム, 構造工学論文集, Vol.37A, pp.687-697, 1991.
- 12) 白木渡, 松保重之: 色彩を考慮したアーチ橋の景観設計へのニューラルネットワークの応用, 構造工学論文集, Vol.39A, pp.595-606, 1993.
- 13) 渡邊英一, 古田均, 森本浩之, 利根川太郎: ニューラルネットワークを用いたダム構造物の景観設計支援システム, 構造工学論文集, Vol.38A, pp.617-624, 1992.
- 14) 保田敬一, 古田均, 神野裕昭, 坂本純男: 橋梁景観設計のための画像データベースとニューラルネットワークによる評価システム, 構造工学における数値解析法シンポジウム論文集, 第 18 巻, pp.151-156, 1994.
- 15) 関口司, 魚本健人, 高田良章, 渡部正: ニューラルネットワークを用いたコンクリート実験のデータ解析に関する研究, 土木学会論文集, 第 460 号/V-18, pp.65-74, 1993.
- 16) 大矢孝, 魚本健人, 堤知明: ニューラルネットワークを用いたコンクリート製造管理システムに関する研究, 土木学会論文集, 第 514 号/V-27, pp.9-18, 1995.
- 17) 安田登, 堤知明, 恒國光義, 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混ぜ品質管理手法, 構造工学論文集, Vol.41A, pp.1015-1021, 1995.
- 18) Rogers, J.L.: Simulating Structural Analysis with Neural Network, *Journal of Computing in Civil Engineering, ASCE*, Vol.8, No.2, pp.252-265, 1994.
- 19) Berke, L., Hajela, P.: Application of Neural Nets in Structural Optimization, *Optimization of Large Structural Systems*, pp.731-745, 1993.
- 20) Kang, H.-T., Yoon, C.J.: Neural Network Approaches to Aid Simple Truss Design Problems, *Microcomputers in Civil Engineering*, 9, pp.211-218, 1994.
- 21) 田中征夫: 満足化・最適化とその適応化, 矢川元基編 ニューラルネットワーク, 第 2 章, pp.11-46, 培風館, 1992.
- 22) 斉藤進, 堀井健一郎, 依田照彦: 対話型ゴールプログラミングを利用した構造最適設計について, 構造工学における数値解析法シンポジウム論文集, 第 18 巻, pp.423-428, 1994.
- 23) 斉藤進, 菅原隆, 今野恵喜, 西村良男: 鋼繊維の分散度, 密度及び配向度と鋼繊維補強コンクリートの曲げ強度との関係, セメント技術年報, 第 34 巻, pp.352-355, 1980.

参考文献

- 1) 八名和夫, 鈴木義武: ニューロ情報処理技術, 海文堂, 1992.
- 2) 市川絃: 階層型ニューラルネットワーク, 共立出版, 1993.
- 3) 馬場則夫, 小島史男, 小澤誠一: ニューラルネットの基礎と応用, 共立出版, 1994.

(1995. 9. 4 受付)

APPLICATION OF NEURAL NETWORKS TO MULTIOBJECTIVE OPTIMIZATION

Susumu SAITOU, Ken'ichirou HORII and Teruhiko YODA

In this paper, the effectiveness of neural networks applied to optimization is presented. By the example of structural optimization, it is shown that the method based on the neural networks can be used as a substitute of the conventional mathematical optimization method. By the example of mix proportion design of concrete, it is shown that the proposed method is applicable to the problem in which the conventional mathematical optimization method is difficult to apply.