

1. はじめに

著者らは、文献1)で、履歴特性を有する非線形振動系を対象に、入出力の時系列観測データを用いて構造化学習を行い、履歴特性とパラメーターを同時に同定する考え方を提案した。しかし、構造化学習のアルゴリズムに関しては詳細に論述していない。そこで、本小文では、エネルギー入力と履歴挙動の骨格構造を形成するための忘却項を導入した評価関数を考案し、グローバルかつローカルな繰り返しによって、モデルの表現能力を高める一連のアルゴリズムを示す。

2. システム同定法の概略

システム同定のフローは図1のようになる。

非線形履歴振動系はSDモデルで表す(文献1)参照)。システム同定のための評価関数 $E(t)$ としては、そのSDモデルのネットワークの出力層における推定誤差(観測応答 $F_{i,out}$ と計算応答値 D_i の差)を考える。その際、拘束条件としては、地震外乱 \ddot{z}_g による振動系へのエネルギー入力の総量を考える。ラグランジュ乗数 λ を用いると、拡張された評価関数 $E_f(t)$ は次式のようになり、これを最小化する。ここで、 ω_0 と β は固有振動数と減衰定数、 x 、 \dot{x} と \ddot{x} は変位、速度と加速度、 $g(x)$ は履歴特性を表す。

$$E_f(t) = \frac{1}{2} \sum_i (F_{i,out}(t) - D_i(t))^2 + \lambda \left\{ \int_0^t (-\ddot{z}_g) \dot{x} d\xi - \left(\int_0^t \ddot{x} \dot{x} d\xi + \int_0^t 2\beta\omega_0 \dot{x}^2 d\xi + \int_0^t \omega_0^2 g(x) \dot{x} d\xi \right) \right\} \dots \dots (1)$$

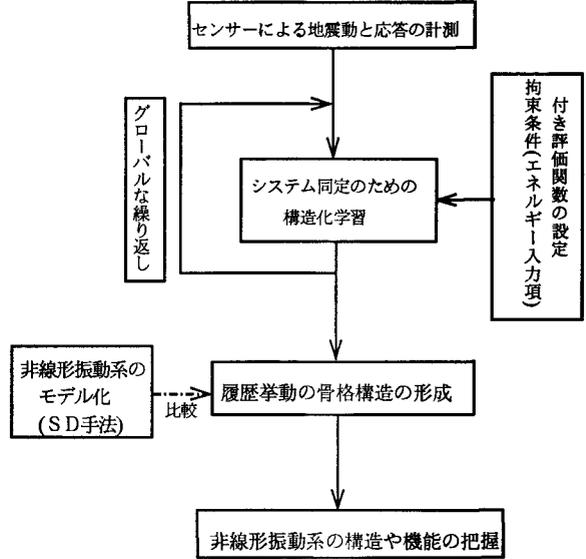


図1 システム同定のフロー

構造化のために、上式の拡張評価関数 $E_f(t)$ に忘却項を追加して、バックプロパゲーション(BP)学習を構築する。さらに、ネットワークの構造が明確になるように、選択的忘却付き学習アルゴリズムを考える。図1に示すように、一度同定された結果を初期条件に置換し、再び構造化学習などを行い、グローバルな繰り返しを実施する。その結果、ネットワーク中に履歴特性の骨格構造を形成させることができる。このようなアイデアは極めて独創的と言える。

3. システム同定のための構造化学習アルゴリズム

図1では、継続時間にわたって、グローバルな繰り返しをしている。一方、図2には、各時間帯(時点 i と時点 $i+1$ の間、 $i=0 \sim n-1$)で、ローカルな繰り返しを含む。図中の中、中と出は、以下に述べるネットワークの入力層、中間層と出力層を意味している。ある時間ブロック(時点 t と時点 $t+1$ の関係)は、1自由度振動系モデルのネットワーク(図3)よりなる。図4は、図3における塑性部分の初期状態のネットワークを示したものである。図3において、構造が既知である弾性部分ではパラメーターのみを同定し、塑性部分においては構造とともにパラメーターをも同定する。

式(1)において、 $F_{i,out}$ は図3に示す最終層のユニット出力、 \ddot{z}_g は第1層の3番目のユニット出力などに対応している。履歴特性の数理式を得るため、ここでは、中間層に3種類のユニットを考

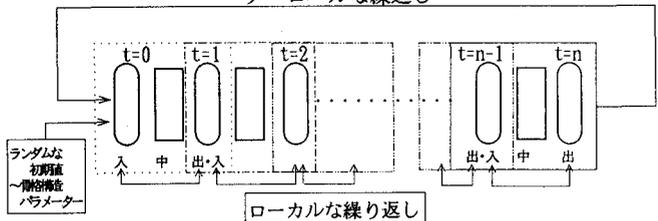


図2 グローバル・ローカルな繰り返しを伴うネットワーク

えた。すなわち、これらは、他ユニットの出力値の加重和で表される和ユニット、加重積で表される積ユニットとシグナム関数によって加重和を変換したsgnユニットに分類される。BPを実施するとき、ネットワークのリンク重みによるこれらの偏微分は異なる式になる。そのため、それぞれに対応して、偏微分の定式化が必要になる。例えば、積ユニットから積ユニットへのリンク重み w による $E(t)$ の偏微分は次式のようにになる。ただし、 $E(t)$ は、出力層における推定誤差、つまり式(1)の拡張評価関数の右辺第1項目に対応している。

$$\begin{aligned} \frac{\partial E(t)}{\partial w_{k,l_j}^{j,l_j}} &= \left\{ \sum_{l_n=l_j-1}^{l_j+1} \sum_{n=1}^{\text{unit}(l_n)} \frac{\partial E(t)}{\partial F_{n,l_n}(t)} \frac{\partial F_{n,l_n}(t)}{\partial F_{j,l_j}(t)} \right\} \frac{\partial F_{j,l_j}(t)}{\partial w_{k,l_j}^{j,l_j}} \\ &= \left[\sum_{l_n=l_j-1}^{l_j+1} \sum_{n=1}^{\text{unit}(l_n)} \frac{\partial E(t)}{\partial F_{n,l_n}(t)} \left\{ \prod_{\substack{l_m=l_n-1 \\ l_m \neq l_j}}^{l_n+1} \prod_{\substack{m=1 \\ m \neq j}}^{\text{unit}(l_m)} w_{m,l_m}^{n,l_n} F_{m,l_m}(t) \right\} w_{j,l_j}^{n,l_n} \right] \\ &\quad \times \left\{ \prod_{\substack{l_m=l_n-1 \\ l_m \neq l_j}}^{l_n+1} \prod_{\substack{m=1 \\ m \neq j}}^{\text{unit}(l_m)} w_{m,l_m}^{j,l_j} F_{m,l_m}(t) \right\} F_{k,l_k}(t) \quad \dots\dots(2) \end{aligned}$$

ここで、 F_{ij} は i 層 i 番目のユニット出力、 w_{ij}^{j,l_j} は l_j 層 i 番目のユニットから l_j 層 j 番目のユニットへのリンク重みを表す。

拘束条件としてエネルギー入力を導入した式(1)の拡張評価関数の偏微分は、影響を受けるリンク重みに対して、考えればよい。つまり、拡張評価関数のエネルギー入力項をそれらのリンク重みで偏微分した式を式(2)に加えればよい。

図3のネットワークはフィードバックを含む。そのため、上述のアイデアのみでは、通常のBP学習法のように、偏微分を正確に計算できない。

例えば、中間層1のユニット出力を計算するには、中間層2のユニット出力が必要となるが、その値は未知である。そのため、初期条件として、まず、中間層2のユニット出力は、入力層のユニット出力に等しいと考える。次に、図2に示すように、ローカルな繰り返しを実施する度に、その近似度は改善されるので、精度は高まる。式(2)の偏微分を計算するときも、同様なテクニックを使う。

3. おわりに

本研究では、文献1)で提案したシステム同定の考え方を拡張し、そのアルゴリズムやテクニックを具体的に示した。紙面の都合上、数値計算結果については講演会当日に発表する。

参考文献

1) 藤田章弘・野田茂・星谷勝・小淵康義：構造化学習による震動系のシステム同定と自己組織化、土木学会第47回年次学術講演会講演概要集、第1部、pp.1336~1337、平成4年9月。

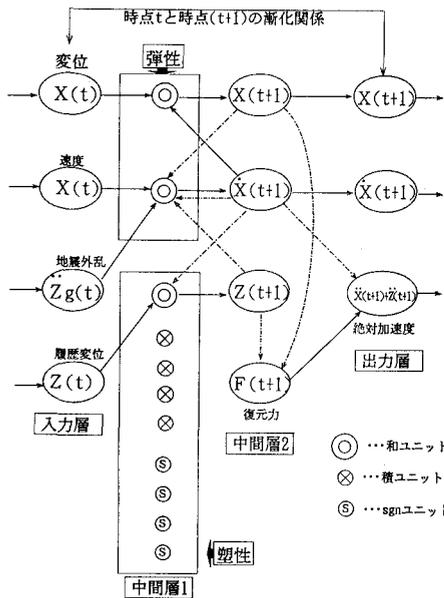


図3 1自由度振動系モデルのネットワーク

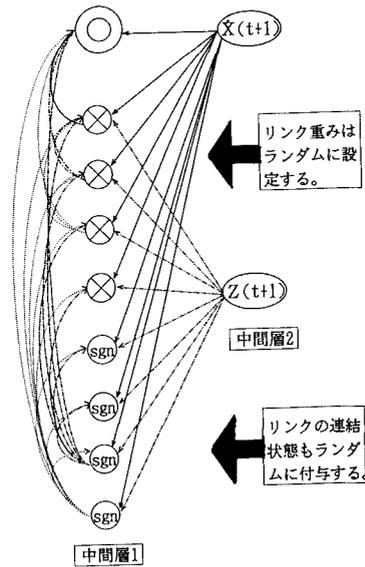


図4 塑性部分のネットワーク(初期状態)