

確率一般化学習ネットワークと その非線形制御システムへの応用

平澤 宏太郎 金 春植
村田 純 一 胡 敬焮
九州大学大学院

本論文では、確率一般化学習ネットワーク (Probabilistic Universal Learning Networks: PrULNs) を用いた非線形システムの制御手法を提案する。確率一般化学習ネットワークは一般化学習ネットワーク (Universal Learning Networks: ULNs) の拡張である。一般化学習ネットワークは非線形大規模複雑系のモデリングや制御系設計のための一般的な枠組みを提供しており、多くのニューラルネットワークのクラスをカバーしている。ULNs のために一般化された学習アルゴリズムが開発されているが、ほとんどの学習ネットワークがこのアルゴリズムによって学習できる。しかしながら、ULNs は確率信号が処理できない。ここで提案する PrULNs は信号の統計的特性量を計算する機構を備えており、また、ネットワークによって処理された信号が所望の確率特性を持つようにパラメータの学習をすることもできる。本論文では、非線形クレーンの制御問題を例に、PrULNs を用いた非線形制御器の設計手法を提案し、数値シミュレーションによりその有効性を検証した。

Probabilistic Universal Learning Network and Its Application to a Nonlinear Control System

Koraro Hirasawa, Chunzhi Jin, Juichi Murata and Jinglu Hu
Graduate School, Kyushu University

In this paper, a nonlinear control system design method by using Probabilistic Universal Learning Networks (PrULNs) is proposed. PrULNs are extension of Universal Learning Networks (ULNs). ULNs form a superset of neural networks and were proposed to provide a universal framework for modeling and control of nonlinear large-scale complex systems. A generalized learning algorithm has been devised for ULNs which can also be used in a unified manner for almost all kinds of learning networks. However, the ULNs can not deal with stochastic variables. Specific value of a stochastic signal can be propagated through a ULN, but the ULN does not provide any stochastic characteristic of the signals propagating through it. The PrULNs proposed here are equipped with machinery to calculate stochastic properties of signals and to train network parameters so that the signals behave with the pre-specified stochastic properties. In this paper, as an example of control of nonlinear crane system, a nonlinear controller design method by using PrULNs is presented, and some numerical simulations are carried out to illustrate the effectiveness of the method.

1. まえがき

学習ネットワークはパターン認識、システム同定と制御等の分野において多数応用されているが、実世界のデータを取り扱うときにはノイズが混入されていることを考慮しなくてはならない。通常の学習ネットワークでは、汎化能力を高める観点から教師信号の選定やネットワークの構造最適化についての議論は行われているものの、ある確率信号が入力されたときにネットワークを通過した出力信号がどのような統計的性質を持つかは検討されておらず、ましてはそれが所定の統計的特性を持つように学習させることはできない。信号処理やシステム制御の分野において、一般にシステムがノイズに強いことが望まれる。そこで積極的に確率信号を処理できるように考案されたのが確率一般化学習ネットワー

クである。

確率一般化学習ネットワークは確率信号処理を念頭において、著者等が提案してきた一般化学習ネットワークを拡張したもので、入力信号の平均・分散等のモーメントが既知のときに出力の平均・分散等が近似的に計算でき、さらに出力信号が望ましい統計的性質を持つように学習することができる。確率一般化学習ネットワークの基本アイデアはすでに公表されている [2] が、確率一般化学習ネットワーク手法はいろんなアプリケーションに適用可能である。

本研究は確率一般化学習ネットワークの非線形制御システムへの応用について述べたものである。第2章で確率一般化学習ネットワークの概要について説明し、第3章では非線形クレーン制御を例とし




図 1: Structure of the PrULNs.

て、非線形動的システムの制御において確率一般化学習ネットワーク手法が有用かつ有効であることを立証する。最後に第 4 章で結論をまとめる。

2. 確率一般化学習ネットワーク

確率一般化学習ネットワークはある処理を表すノードとそれぞれのノードを結ぶブランチから構成される。各ノードはシグモイド関数、ラジアルベイスファンクションのようなノード処理関数をとるのが可能であり、また、通常のシグモイドニューラルネットワークやニューロファジーネットワークも処理関数として採用できる。ノード間のブランチには任意の遅れ時間をおくことができ、また、二つのノード間を多数のブランチで連結することが許される。従って、確率一般化学習ネットワークはいろいろなアプリケーションに柔軟に対応して、その構造を選ぶことができ、モデルや制御に関する先見知識を容易にネットワークの中に取り込める。確率一般化学習ネットワークの構造を図 1 に示す。また、確率一般化学習ネットワークの基本式は次のとおりである。

$$h_j(t) = f_j(\{h_i(t - D_{ij}(p)) | i \in JF(j), p \in B(i, j), \{r_n(t) | n \in N(j)\}, \{\lambda_m(t) | m \in M(j)\}\}), \quad (1)$$

$$j \in J, t \in T$$

ここで、 $h_j(t)$: j ノードの t 時刻の出力値、 $r_n(t)$: n 外部入力変数の t 時刻の値、 $\lambda_m(t)$: m パラメータの t 時刻の値、 f_j : j ノードの非線形関数、 $D_{ij}(p)$: i ノードより j ノードへの p 番目のブランチの遅れ時間、 J : ノード番号の集合、 $JF(j)$: j ノードへ接続するノード番号の集合、 $N(j)$: j ノードへ接続する外部入力変数番号の集合、 $M(j)$: j ノード出力を偏微分可能なパラメータの番号の集合、 $B(i, j)$: i ノードから j ノードへ接続するブランチの番号の

集合、 T : サンプル時刻の集合である。

ここで、ある時刻 t における p 番目のノード出力 $y_p(t)$ の平均と p と q ノード出力の共分散の計算を考える。まず、簡単のため、(1) 式の変数のうち確率的に変化する変数だけに注目し、他の変数を省略すると

$$h_p(t) = \text{Dynamic}(\{x_\alpha(t_\ell) | \alpha = 1, 2, \dots, \ell = 1, 2, \dots\}) \quad (2)$$

のようになる。 $x_\alpha(t_\ell)$ は入力確率変数である。(2) 式について各入力確率変数の平均 $E[x_\alpha(t_\ell)]$ を中心に 2 次項までテーラ展開し、集合平均を取るとノード出力の平均が求まる。

$$E[h_p(t)] = \text{Dynamic}(\{E[x_\alpha(t_\ell)] | \alpha = 1, 2, \dots, \ell = 1, 2, \dots\}) + \frac{1}{2} \sum_{\alpha, \beta, \ell, m} \frac{\partial^2 h_p(t)}{\partial x_\alpha(t_\ell) \partial x_\beta(t_m)} \cdot \text{Cov}[x_\alpha(t_\ell), x_\beta(t_m)] \quad (3)$$

また、共分散は

$$\text{Cov}[h_p(t), h_q(s)] = E[(h_p(t) - E[h_p(t)])(h_q(s) - E[h_q(s)])]$$

であることから、(2) と (3) 式を用いてそれぞれ $h_p(t) - E[h_p(t)]$ 、 $h_q(s) - E[h_q(s)]$ を計算してから上式に代入し整理すると、共分散は次のように計算できる。

$$\text{Cov}[h_p(t), h_q(s)] = \sum_{\alpha, \beta, \ell, m} \frac{\partial h_p(t)}{\partial x_\alpha(t_\ell)} \frac{\partial h_q(s)}{\partial x_\beta(t_m)} \cdot \text{Cov}[x_\alpha(t_\ell), x_\beta(t_m)] + \frac{1}{2} \sum_{\alpha, \beta, \gamma, \ell, m, n} \frac{\partial^2 h_p(t)}{\partial x_\alpha(t_\ell) \partial x_\beta(t_m)} \frac{\partial h_q(s)}{\partial x_\gamma(t_n)} \cdot \mu_3[x_\alpha(t_\ell), x_\beta(t_m), x_\gamma(t_n)] + \frac{1}{2} \sum_{\alpha, \beta, \gamma, \ell, m, n} \frac{\partial^2 h_q(s)}{\partial x_\alpha(t_\ell) \partial x_\beta(t_m)} \frac{\partial h_p(t)}{\partial x_\gamma(t_n)} \cdot \mu_3[x_\alpha(t_\ell), x_\beta(t_m), x_\gamma(t_n)] \quad (4)$$

ここで、偏微分記号 ∂ の右肩に $+$ 記号がつくのは ordered 微分を表し、 $\mu_3[\cdot, \cdot, \cdot]$ は 3 次の中心モーメントを表す。

確率一般化学習ネットワークは構造上通常の学習ネットワークより大きく拡張しており、多層型ネットワークやリカレントネットワークを含む大きなクラスをカバーする。このようなネットワークのために高次 ordered 微分の順伝播・逆伝播アルゴリズムが整備され、出力の2乗誤差のみならず、出力の統計的特性量を規定する指標も評価関数の成分として考えられ、それに対応する汎用の学習アルゴリズムが提案されている [2]。 (3), (4) 式から分かるように、ノード出力変数の平均と分散の計算には2次微分の演算が必要であり、それを評価指標とすると、勾配法の学習においてはさらに一次高い微分の計算が必要であるが、汎用アルゴリズムにより最適化できる。紙面の都合上、学習アルゴリズムの紹介は省くが、興味のある方は文末の参考文献を参照されたい。

システム制御に確率一般化学習ネットワークを適用する場合は、システム上で定義された一般的な評価指標 J に対してコントローラ内の未知パラメータ $\lambda_1(t), \lambda_2(t), \dots, \lambda_m(t)$ の高次 ordered 微分 $\partial^{+m} J / \partial \lambda_1(t) \partial \lambda_2(t) \dots \partial \lambda_m(t)$ を順伝播・逆伝播で体系的に計算する。従って、これらを利用して評価指標が最小となるコントローラのパラメータを探索することが可能である。換言すると、制御対象とコントローラの両者をまとめて一つのネットワークと考え、このネットワーク上の信号の伝播により、任意のノード出力 h について λ に関する高次微分を計算し、勾配法に基づいて学習を行い、コントローラの最適設計を実現する。

3. 非線形システムの制御への応用

本章では、非線形クレーン制御系を例に確率一般化学習ネットワークを使用したコントローラの最適設計問題について検討する。図2に示すように、クレーンシステムの出力に外乱が混入していることを想定しているが、出力値の平均値は本来の目標値、また分散は可能な限り小さくなるようにネットワークコントローラを設計する。

3.1 対象システム

対象となる非線形クレーンシステムを Fig.3 に示す。このクレーンシステムの運動方程式は、台車の位置を x [m]、荷の振れ角を θ [rad]、荷の巻き上げ位置を ℓ [m] とすると、

$$\frac{d^2 x}{dt^2} = -\frac{mg}{M}\theta - \frac{D+G}{M}\frac{dx}{dt} + \frac{G}{M}u_1 \quad (5)$$




図 2: Control System with Stochastic Disturbance.




図 3: Nonlinear Crane System.

$$\frac{d^2 \theta}{dt^2} = -\frac{M+m}{\ell M}g\theta - \frac{D+G}{\ell M}\frac{dx}{dt} + \frac{G}{\ell M}u_1 \quad (6)$$

$$\frac{d^2 \ell}{dt^2} = -\frac{C+G_m}{m}\frac{d\ell}{dt} + \frac{G_m}{m}u_2 \quad (7)$$

と表される。ただし、 u_1, u_2 : 横走行、巻き上げモータ入力電圧 [V]; C : 巻き上げ摩擦係数 [kg/sec]; M : 台車の質量 [kg]; D : 横走行摩擦係数 [kg/sec]; m : 荷の質量 [kg]; G, G_m : 台車・巻き上げ系の電圧-力係数 [N/V]; g : 重力加速度 [m/sec²] である。これを離散化し、一般化学習ネットワークでは、6個のノードで表現した。コントローラについては、入力の線形加重をとる処理と、 \tanh 関数により非線形処理を行う2個のノードをリカレント接続したものを2組用意し、それぞれが u_1, u_2 を出

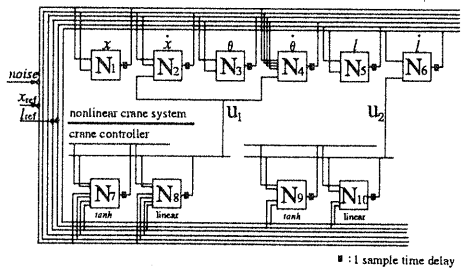


図 4: Control Model of the Crane System by PrULNs.

力する。各コントローラノードに接続する結合重みとノードの閾値パラメータの値は学習によって獲得する。Fig.4 に一般化学習ネットワークで構成されたリカレント型システムモデルを示す。遅れ時間は全て 1 サンプル遅れとした。

3.2 評価指標の設定

比較のため、次のように通常の 2 乗誤差指標と平均・分散を考慮した評価指標を設定し、それぞれ制御器パラメータの学習を行った。

- 通常的评价指標

$$\begin{aligned}
 E_N &= \frac{1}{2} \left[\sum_{s \in T} \{ Q_{n1} (x_{ref} - x(s))^2 + Q_{n3} \theta(s)^2 \right. \\
 &\quad + Q_{n4} \dot{\theta}(s)^2 + Q_{n5} (\ell_{ref} - \ell(s))^2 \\
 &\quad + R_{n1} u_1(s)^2 + R_{n2} u_2(s)^2 \} \\
 &\quad \left. + Q_{n2} \dot{x}(t_f)^2 + Q_{n6} \dot{\ell}(t_f)^2 \right] \quad (8)
 \end{aligned}$$

- 平均と分散を考慮した評価指標

確率一般化学習ネットワーク理論で提案している評価指標を設定すると、以下のようになる。

$$L_{MV} = E_M + E_V \quad (9)$$


$$\begin{aligned}
 E_M &= \frac{1}{2} \left[\sum_{s \in T} \{ Q_{m1} (x_{ref} - E[x(s)])^2 \right. \\
 &\quad + Q_{m3} (E[\theta(s)])^2 + Q_{m4} (E[\dot{\theta}(s)])^2 \\
 &\quad + Q_{m5} (\ell_{ref} - E[\ell(s)])^2 + R_{m1} (E[u_1(s)])^2 \\
 &\quad + R_{m2} (E[u_2(s)])^2 \} \\
 &\quad \left. + Q_{m2} (E[\dot{x}(t_f)])^2 + Q_{m6} (E[\dot{\ell}(t_f)])^2 \right] \quad (10)
 \end{aligned}$$

$$\begin{aligned}
 E_V &= \sum_{s \in T} \{ Q_{v1} \text{Var}[x(s)] + Q_{v2} \text{Var}[\dot{x}(s)] \\
 &\quad + Q_{v3} \text{Var}[\theta(s)] + Q_{v4} \text{Var}[\dot{\theta}(s)] \} \quad (11)
 \end{aligned}$$


これらの評価指標は RasID[3] を用いて最適化する。

3.3 結果及び考察

各コントローラの重み係数・閾値の初期値は $[-0.1, 0.1]$ の乱数で与え、それぞれに評価指標に対して十分収束できるよう、10 万回学習した。図 5 は得られたコントローラによって、クレーンを制御した場合の時間応答を示したものである。図 5(a) はノイズのない場合で、両者にはさほど差がないが、図 5(b) の平均 0、分散 1 のノイズが加わった場合においては、平均と分散を評価指標に入れて学習した方が、ノイズに対する耐性がよく、確率一般化学習ネットワークの手法が有効である。



(a) Results without Noise



(b) Results with Noise

図 5: Control Results in case of Criterion L_{MV} .

4. まとめ

本論文では、非線形システムのモデル化と制御を行うための一般化学習ネットワークに確率の伝播を導入した確率一般化学習ネットワーク理論について述べ、つぎに、これを非線形クレーンシステムにおけるコントローラ的设计問題へ適用し、平均値や分散の有効な制御が可能であることを示している。

今後、本手法を、確率変数の混在した各種のネットワークあるいは制御システムに展開するための研究を積極的に進めてゆく予定である。

参考文献

- [1] 平澤, 大林: 一般化学習ネットワーク理論, 電気学会論文誌, **116C**-7, 794/801 (1996)
- [2] 平澤, 大林, 村田, 胡: 確率一般化学習ネットワーク理論, 電気学会論文誌, **118C**-2, 224/231 (1998)
- [3] J. Hu, K. Hirasawa, J. Murata: RasID - Random Search for Neural Network Training, Journal of Advanced Computational Intelligence, **2**-4, (1998)