

熱の流れ解析におけるニューラルネットワーク記述による

4 P - 1

パッケージフローモデル

丸繁 卓彦* 石黒 美佐子**

*茨城大学理工学研究科 **茨城大学工学部

1. 研究概要

システム挙動を直感的に把握するためのシミュレーション手法であるパッケージフローモデル(PFM)^[1]を1つのオブジェクトとして記述することを提案し^[2], セントラルヒーティングシステムの流れ解析に適用した. 本稿では, 物理的現象をつかさどるパラメータの1つである落下密度関数をニューラルネットワークの教師付き学習をさせることで, システム挙動を支配する物理現象のメカニズムを明確にし, より最適な解を得る.

2. PFM の概要^[3]

多くのシステムは, エネルギーや質量のように保存則によって支配される粒子の流れシステムと考えることができる. PFM は, 現実のシステム特性のうち, 応答の時間遅れに注目し, 粒子流れを物理段階ごとに計算する. 仮想流れのあるまっすぐなパイプを考える. 注目している粒子が, ある与えられた“収集率”で集められ, あるパターン分布(落下関数 $w(x)$)で仮想流れに落とされる. パイプの出口からの“流出率”は, 次式によって計算される.

$$f = \sum_{i=0}^n w_i q(n-i) v(n-i) \quad (1)$$

ここで n は現時間ステップで, w_i は時刻 $n-i$ に落下した粒子の重みで, 落下密度関数 $w(x)$ から得られる. $q(n)$ は時刻 t_n での収集率である.

各物理段階を数個の PFM によって置きかえることにより, システム全体を記述することが出来る.

3. ニューラルネットワーク導入の動機

計算式(1)の手順を実行するには, 落下密度関数が重要となる. 多くの場合, その分野の専門家であれば, 落下密度関数の大体の形は想像できる. 最適な分布は, 試行錯誤によって得られる事もあるが, 手間がかかり, パラメータを動かす範囲に誤りが生じるかもしれない. そこで, 最適な落下密度関数を得るためにニューラルネットワークの学習機能を用いる.

“流出率”の計算式(1)を検討すると, それは過去の“収集率”に“落下密度関数”で得られた重みを乗じて加算するという形になっている. これは, 1つの

“Package Flow Model by Neural Network Representation for Heat Flow Analysis”

Takuhiko MARUSHIGE, and Misako ISHIGURO
IBARAKI University, Nakanarusawa-cho, Hitachi-city,
316, Japan

PFM の計算が, 1つの人工ニューロンの計算に対応する事を意味している (Fig.1). ここで, 重みは落下密度関数から得られる. 従って, 考察している物理段階はそれに対応するニューラルネットワークで表現する事ができ, 学習によって最適な重みを得る事ができる.




Fig.1 Artificial neuron corresponding to PFM

4. 学習方法

ここでは最急降下法による学習アルゴリズムを用いる. 重みベクトル $\mathbf{W} = (W_0, W_1, \dots, W_r)^T$ を変数とする誤差関数を以下のように定義する.

$$E(\mathbf{W}) = (1/p) \sum_{c=1}^p \{S_c(\mathbf{W}) - d_c\}^2 \quad (2)$$

p は比較したいデータの数である. $S_c(\mathbf{W})$ は時刻 t_c の流出率, d_c は教師データ, δ_c は変換値である.

$$S_c(\mathbf{W}) = a_{c0}W_0 + a_{c1}W_1 + \dots + a_{cr}W_r \quad (3)$$

$$\text{但し, } a_{ci} = q(c-i)/v(c-i) \cdot v(c).$$

重みベクトルの更新では, $(i+1)$ 回の学習後の $\mathbf{W}(i+1)$ を以下のように定義し, ϵ を求める.

$$\mathbf{W}(i+1) = (\mathbf{W}(i) + \epsilon)/(1 + \epsilon)$$

$$\epsilon = \epsilon_0 + \epsilon_1 + \dots + \epsilon_r, \quad 0 < \epsilon < 1 \quad (4)$$

実際の計算手順は以下ようになる.

S1: 誤差関数が最小になるように ϵ'_m を決定.

$$\epsilon'_m = -\theta \left[\sum_{c=1}^p \{S_c(\mathbf{W}(i)) - d_c\} \{a_{cm} - S_c(\mathbf{W}(i))\} / \delta_c \right]$$

S2: $W_m(i) + \epsilon'_m \geq 0$ ならば, $\epsilon_m = \epsilon'_m$

$$\text{それ以外なら, } \epsilon_m = -W_m(i)$$

S3: $\epsilon = \epsilon_0 + \epsilon_1 + \dots + \epsilon_r$

S4: 重み値を更新する.

$$W_m(i+1) = (W_m(i) + \epsilon_m)/(1 + \epsilon)$$

5. 計算結果と考察

Fig.2 に示すセントラルヒーティングシステムを考える。PFM のネットワークによって全システムが Fig.3 のように表現される。PFM 1はタンクから配管への湯の流入，PFM 3はタンクから空調への熱の流入，PFM 5は空調からタンクへの熱の流入を表わし，PFM 2, PFM4, PFM6 は配管からの熱の漏れを表わしている。

給湯部分は PFM 1 と PFM 2 の流出率から現時刻 t_n での蛇口から流出する湯の温度を計算する。詳しくは文献[3]参照。




Fig. 2 Central heating system

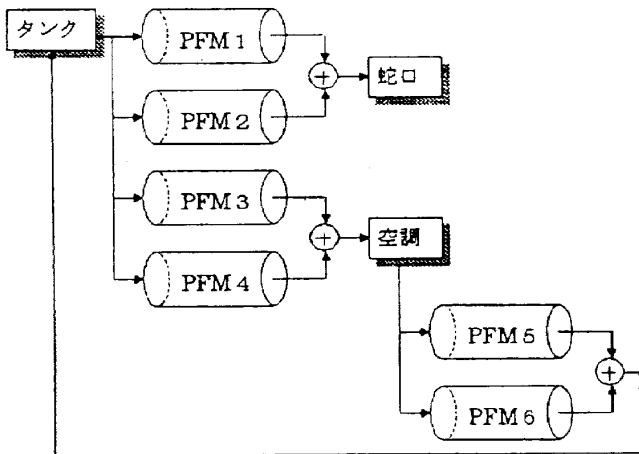


Fig. 3 PFM network for central heating system

給湯量一定時の PFM1 の落下密度関数(重み)をアルゴリズムに基づき学習した。PFM1 の学習の推移を，Fig.4 に示す。学習前の重み値分布は，湯の流れに伴った対流拡散を考慮し，直感的に山形に定めた。学習前の誤差関数は $E(W) = 6.4 \times 10^{-2}$ で，1回の学習で $E(W) = 6.5 \times 10^{-3}$ と大きく減少し，3回目以降は $E(W) = 1.4 \times 10^{-4}$ 程度で，効率よく学習している。

学習プロセスを通して，当初与えた重み分布よりも学習後の重み分布はより大きな広がりを持っていることがわかる。これは対流拡散の効果が，直感的に定めたものよりも大きいことを示している。

蛇口での温度を計算した結果を Fig.5 に示す。グラフの示す通り，差分法による教師データと PFM 法による計算結果はよく一致している。




Fig. 4 Learned weight value of PFM1

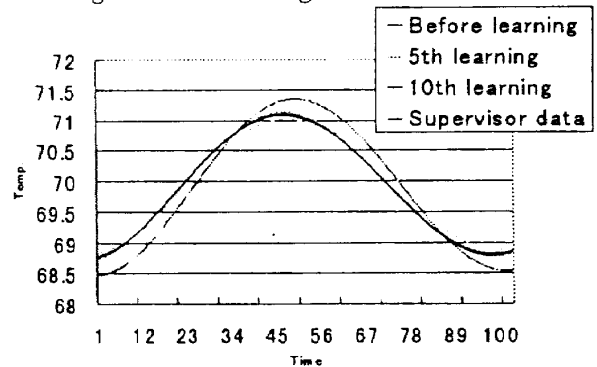


Fig. 5 Computing result for PFM1 when constant water supply

6. まとめ

本研究は，PFM における学習方法を提示し，その応用として，セントラルヒーティングシステムの熱伝導問題の例を示した。落下密度関数の形が，重み値の最適化プロセスを通して調節され，その最適化された形から熱伝導現象の時間遅れについて理解を得ることができた。さらに，最適化された落下密度関数をシミュレーションに用いることで，より正確な解が得られることを示した。

参考文献

[1] Matsuoka, H. and Ishiguro, M.: Package Flow Model by Neural Network Representation for Understanding the Dynamic Behavior of Nuclear Reactor Systems, J. Nucl. Sci. Technol., 33[9], 675-685 (1996).
 [2] 丸繁, 石黒, 坪井: 熱の流れ解析におけるパッケージフローモデルのオブジェクト指向プログラミング, 情報処理学会第 56 回全国大会 1S-02, (1998).
 [3] 石黒, 松岡, 丸繁: パッケージフローモデルによる熱の流れ解析, 情報処理学会 MPS 研究会, (July, 1998)