

## 空調制御における ARX モデルに基づく機械学習機能の安定性向上

Improvement of stability of machine learning function based on ARX model in air conditioning control

廣石 健悟\*1

Kengo Hiroishi

山田 哲靖\*1

Tetsuyasu Yamada

\*1 公立諏訪東京理科大学

Suwa University of Science

## 1. はじめに

一般の空調システムにおいて、PID 制御の各ゲインは竣工前の試運転調整時に専門業者によって固定値に設定され、運用されている。しかし、空調制御の多くは気候変動による時変性や非線形性を有しており、各ゲインを固定値とした PID 制御にて、常に所望の制御性能が得られるとは限らない。本研究では、空調制御盤内の PID 制御に学習機能を外付けで組み込み、運用しながら最適ゲインを自動設定することで、制御不具合の解消とゲイン設定業務の省力化を図ることを目指し、研究開発に取り組んでいる。その中で、PID ゲイン変数を作成し機械学習を用いて運転条件に合わせて自動的に調整することで制御性を向上させる過程において、変数の算出の安定性が課題となった。この課題に対する分析を改善手法の立案の検討を行った。

## 2. 制御システム

開発をしている制御システムのブロック線図を図-1に示す。コンピュータ上で、空調システムを一次遅れ+むだ時間モデルで表現し、シミュレーションにより PID ゲインの最適解を導出し、実システムの PID ゲインを自動的に書き換える。システムパラメータの機械学習(システム同定)方法には、ARX(Auto-Regressive with eXogenous)モデルを採用している。以下に一次遅れ+むだ時間の式を示す。

$$G(s) = \frac{K}{1 + T_s s} e^{-Ls} \quad (1)$$

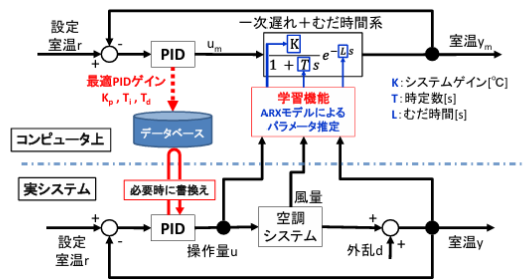


図 1 制御システムのブロック線図

上記制御システムを、空調負荷が成行きで推移する実フィールドの空調システムにおいて人の手を介さず動作させるために、学習データの自動抽出機能を設けている。すなわち、過去の運転データを、各種運転パラメータの組み合わせごとに「分類」し、それぞれの条件でシステム同定と

PID ゲインの最適化計算を行い、結果をデータベースに保管する。以降は、運転状態ごとにデータベースより最適 PID ゲインを読み出し運転する。学習に用いる時系列データには、システムの時間遅れ特性を同定できるよう、操作量  $u$  及び室温  $y$  の適度な時間変動が含まれており、さらに両者の時間遅れ関係が学習データ内に収まっている必要がある。この時系列データは、長時間であるほど外乱の影響が相対的に小さくなり、推定精度が向上すると考えられるが、実フィールドにおいて同じ運転状態(空調負荷)が続く時間には限りがあるので、必要かつ十分な時間長さで、学習データを分割・抽出する技術が求められる。

## 2.1 学習機能

空調を含むプロセス制御は、物理現象に基づく厳密なモデリングが困難であることが知られている。本研究の先行研究では空調などのプロセス制御の時間遅れ特性を表現する用途で実績のある、一次遅れ+むだ時間系モデルを室温の予測に使用している。システムの動的特性影響を与えるパラメータ(熱負荷、流量など)によって、一次遅れ+むだ時間系のパラメータは変化するため、状況に応じた制御を行うためには、各条件でステップ応答試験を実施することが望ましい。これに対し、応答試験を行わずにこれらパラメータを求める方法が提案されており、その一つである ARX モデルにより時間遅れ特性を推定する手法を取り入れている。この機能により、実システムより得られたデータを入力として、ARX モデルに基づく機械学習を行い、空調システム伝達関数の特性パラメータ( $K \cdot T \cdot L$ )の推定を行う。

## 2.2 現状の課題と分析

上記 2.1 で記述した ARX モデルに基づく機械学習機能には、算出されるパラメータが安定しないという課題が存在する。これにより、運転が不安定化する恐れがある。そのため、ARX モデルに基づく機械学習機能によって算出された、特性パラメータと誤差(loss)を可視化し分析を行った。手法としては、各実行 500 トライアルの探索結果から二つのパラメータと誤差を 3次元空間上にプロットすることで可視化を図った。これにより、算出結果として大きく 3種類に分類されることが分かった。それぞれの種類について以下に記述する。

## ① モール型

モール型は図のように、探索範囲の中心付近に探索結果が点在している。探索結果内には、探索範囲の

上下限に探索点が集中しているものもあり、それらはモール型には含まない。




図2 モール型

### ② K 下限集中型

K 下限集中型は図のように、パラメータ K の探索結果が、下限値である 8 付近に集中することで下限付近において直線をなしているように見て取れる型である。




図3 K 下限集中型

### ③ L 集中型

L 集中型は図のように、K-T、T-L、L-K のグラフが直線上になっており、L はほぼ一定の値を取ることが分かる。




図4 L 集中型

## 2.3 考察

前述した3つの型に分けられる理由として考えられるのは、L で表されるむだ時間が定まっていないことに起因すると考えられる。本来であれば、むだ時間とは入力信号の形を変えずに一定時間遅れて集中定数系に加えられるものであり、空調機においては、配管の長さや送風能力に起因するものと考えられるため大きくばらつくことは考えにくい。

次に数式上で考える。むだ時間は以下の式(2)で表される。

$$G(s) = e^{-Ls} \quad (2)$$

この式に  $s = i\omega$  とおき、オイラーの公式を適用すると

$$G(i\omega) = e^{-i\omega L} = \cos \omega L - i \sin \omega L \quad (3)$$

となる。したがって、

$$|G(i\omega)| = \sqrt{\cos^2 \omega L + \sin^2 \omega L} = 1 \quad (4)$$

となり、むだ時間の大きさは  $\omega$  に関係なく一定であることが分かる。

このことから、むだ時間の予測における運転上では起こりえないばらつきが全体の予測が不安定化しているのではないかと考える。つまり、むだ時間の予測がほぼ一定となっている、L 集中型の予測結果が本システムの予測結果において最も正確なものであるといえる。

K 下限集中型は、K の予測幅が非常に狭くなってしまっている。空調機におけるゲインとは、室温の可変能力であることから低すぎる値は望ましくないと考えられる。

## 3. おわりに

考察から、むだ時間の予測の不安定性が大きく影響を与えていることが分かった。このことから、むだ時間の算出手法を変更する必要性を感じた。現在の案としては、むだ時間のみ初期時のステップ応答試験で計測した値を使用するなどが考えられている。また、L の値によって閾値をもうけるなども考えられる。

### 参考文献

- [1] 福田ら：空調におけるAIを活用した制御技術の開発（第1報）TPEによるPIDゲイン調整機能の検討，空気調和衛生工学会講演論文集(2019)。
- [2] 福田ら：空調におけるAIを活用した制御技術の開発（第2報）ARXモデルに基づく機械学習による適応制御の検討，空気調和衛生工学会講演論文集(2020)。
- [3] 福田ら：空調におけるAIを活用した制御技術の開発（第3報）適応制御のためのデータ自動抽出方法並びにパラメータ高精度推定方法の検討，空気調和衛生工学会講演論文集(2021)。
- [4] 山本重彦・加藤尚武，PID制御の基礎と応用，第2版，朝倉書店，2018，p150