

知識情報処理を用いた活性汚泥プロセスの シミュレーション

小林 猛、本多裕之、花井泰三、上田尚廉

名古屋大学大学院工学研究科生物機能工学専攻
生物プロセス工学講座
名古屋市千種区不老町

概要

活性汚泥プロセスには多数の微生物が存在し、それぞれの相互作用は大変複雑である。そのためこの系は非線形度が非常に高く、従来の線形解析法および数学モデルにより構築されたシミュレータでは、精度の高いものが期待できない。そのため本研究では、ファジィニューラルネットワーク（FNN）を用いて活性汚泥プロセス中のエアレーションタンク中のシミュレータを構築した。構築したシミュレータは放流水中のCODを高い精度で推定することが可能であった。

キーワード

活性汚泥プロセス、シミュレーション、ファジィニューラルネットワーク

1. はじめに

現在、下水処理場の各プロセスは、オンラインで様々な計測データの収集が行われ、それをもとに、エキスパートの経験と勘による判断で運転管理が行われている。この経験と勘を制御に生かす方法としてファジィ推論が注目されているが、一般にファジィ推論に用いられるメンバーシップ関数、ファジィルールのチューニングは試行錯誤法によって行われ、多くの時間が必要とされる。特に下水処理プロセスのように季節や時間による水質、水量の変化が大きい場合、それぞれにファジィ推論システムの構築の必要があり、多くの労力を必要とする。そのため本研究ではチューニングを自動的に行うFNNを行い、放流水のCODを推定するモデルを2つの処理場のデータを用い構築を行い、シミュレーションによりモデルの妥当性を検討した。

2. シミュレータの構築

2.1 解析に用いたデータ

N市U処理場の平成6年8月の第1週およびH市A処理場の平成7年6月から8月までの時系列データを用いた。U処理場についてのフロー図、および測定項目をFig.1に示す。(a)-(g)の各場所に計測器が設置され、それぞれの測定項目が毎時間測定されている。また、曝気槽および、(b)、(c)、(f)、(g)の測定器は2系列設置されている。時間Tにおけるこれら測定データと(a)、(b)、(c)、(e)、(f)、(g)の6時間の積算値、および(b)、(c)、(f)、(g)の1系と2系の平均値を加えた合計42項目の入力変数から、時間T+1のCODの推定を行った。第1週間の約半分の81点をFNNの学習用、残りの82点を評価用に用いた。

A処理場の場合、毎日の流入水中のCOD、SS、初沈池越水のCOD、SS、曝気槽中のDO、SS、SV、酸素利用速度、返送汚泥中のSS濃度、およびその日の各プロセスの処理量の測定データを用い、D日の測定データからD+1日の放流水中のCODの推定を行った。37点をFNNの学習用、16点を評価用に用いた。

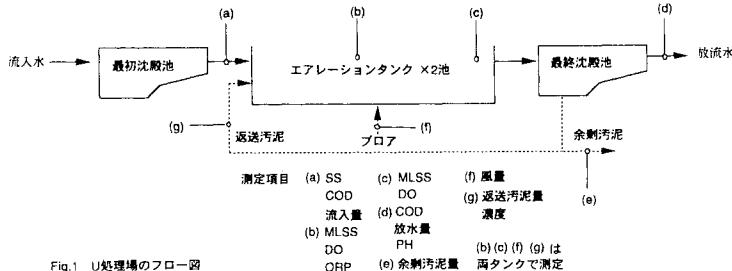


Fig.1 U処理場のフロー図

2.2 ファジィニューラルネットワーク

ファジィニューラルネットワーク (FNN) は知識情報処理手法の一つで、ファジー推論のルールおよびメンバーシップ関数をニューラルネットワークのバックプロパゲーション則を用いて自動チューニングを行うものである。本研究では、我々が吟醸酒の評価用に利用したFNN^{1, 2)}を使用した。その構造をFig.2に示す。このFNNは後件部の W_f でルールを、前件部の W_c 、 W_g でメンバーシップ関数の中心および傾きを表す。学習を行うことで W_f 、 W_c 、 W_g の同定を行い、ネットワークの構造を決定する。またファジィモデルは、入出力関係がファジィルールとして言語的に表されることから、ニューラルネットワークと比較し、定性的で理解しやすいと言う特徴を持っている。

FNNの学習条件は学習係数0.1、最大学習回数2000回とし、 J 値が最小となるところで学習を終了した。

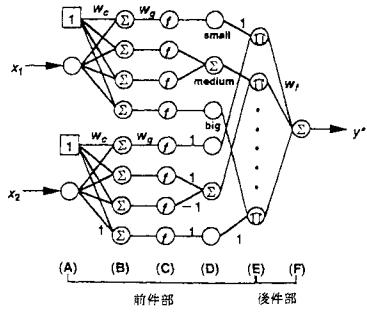


Fig.2 FNN のモデル構造図

2.3 変数増加法

FNNは目的の変数と関係のない変数が入力に存在すると誤差が多くなる傾向があるので、入力変数を最適化するために変数増加法を用いてモデリングを行った。この手法を入力変数10個の系に適応した例をTable.1に示す。 J_1 は学習用データの平均自乗誤差、 J_2 は評価用データの平均自乗誤差であり、それら平均値 J をモデルの評価規範とした。まず入力変数を1つとし、すべての変数について学習を行う。そのとき一番 J の小さい変数を1つ目の入力変数として選択する。この操作を1ステップとする。つぎに選択した入力変数に1つ変数を加え2入力とし学習を行う。このステップを J 値が増加するまで繰り返すことで最適な入力数、入力変数を決定することができる。またデータ数の関係でFNNの最大のステップ数は6と設定した。

対照解析法として、同様の方法で線形モデリングの重回帰分析 (MRA) との比較を行った。

Table.1 変数増加法モデリング

Step	input variable	J_1	J_2	J
1	$x_1[2]$	0.027	0.039	0.033
	$x_2[2]$	0.034	0.028	0.031
	$x_3[2]$	0.033	0.034	0.034
	$\circ x_4[2]$	0.014	0.016	0.015
	$x_5[2]$	0.027	0.041	0.034
	$x_6[2]$	0.031	0.032	0.031
	$x_7[2]$	0.030	0.035	0.033
	$x_8[2]$	0.028	0.040	0.034
	$x_9[2]$	0.027	0.047	0.037
	$x_{10}[2]$	0.028	0.037	0.033
2	$x_4[3]$	0.013	0.016	0.015
	$x_4[2] \times x_2[2]$	0.013	0.019	0.016
	$\circ x_4[2] \times x_2[2]$	0.011	0.017	0.014
	$x_4[2] \times x_5[2]$	0.013	0.016	0.015
	$x_4[2] \times x_5[2]$	0.014	0.015	0.015
	$x_4[2] \times x_6[2]$	0.014	0.016	0.015
	$x_4[2] \times x_7[2]$	0.014	0.016	0.015
	$x_4[2] \times x_8[2]$	0.014	0.016	0.015
	$x_4[2] \times x_9[2]$	0.014	0.019	0.016
	$x_4[2] \times x_{10}[2]$	0.014	0.016	0.015
4	$x_4[3] \times x_2[2]$	0.008	0.022	0.015
	$\circ x_4[3] \times x_2[3]$	0.009	0.016	0.012
	$x_4[3] \times x_2[2] \times x_1[2]$	0.008	0.018	0.013
	$x_4[3] \times x_2[2] \times x_3[2]$	0.012	0.015	0.014
	$x_4[3] \times x_2[2] \times x_5[2]$	0.008	0.019	0.014
	$x_4[3] \times x_2[2] \times x_6[2]$	0.008	0.018	0.013
	$x_4[3] \times x_2[2] \times x_7[2]$	0.009	0.017	0.013
	$x_4[3] \times x_2[2] \times x_8[2]$	0.011	0.016	0.014
	$x_4[3] \times x_2[2] \times x_9[2]$	0.013	0.022	0.018
	$x_4[3] \times x_2[2] \times x_{10}[2]$	0.013	0.017	0.015
5	$x_4[4] \times x_2[3]$	0.009	0.019	0.014
	$x_4[3] \times x_2[4]$	0.010	0.023	0.016
	$\circ x_4[3] \times x_2[3] \times x_1[2]$	0.008	0.017	0.013
	$x_4[3] \times x_2[3] \times x_3[2]$	0.010	0.017	0.014
	$x_4[3] \times x_2[3] \times x_5[2]$	0.009	0.020	0.014
	$x_4[3] \times x_2[3] \times x_6[2]$	0.013	0.018	0.015
	$x_4[3] \times x_2[3] \times x_7[2]$	0.009	0.022	0.016
	$x_4[3] \times x_2[3] \times x_8[2]$	0.008	0.018	0.013
	$x_4[3] \times x_2[3] \times x_9[2]$	0.013	0.023	0.018
	$x_4[3] \times x_2[3] \times x_{10}[2]$	0.014	0.017	0.015

$x_i [k]$: k は入力変数 x_i のメンバーシップ関数の分割数

○: 各ステップの誤差が最小のモデル

◎: 最適なモデル

3. 推定結果

3.1 モデリングによって選ばれた構造および推定結果

U処理場のデータを用い、MRAとFNNモデリングの結果として選択された入力変数をTable.2に示す。これらを比較すると、エアタンク風量（6H積算）、初沈CODは共通の入力変数として選択されており、非常に重要な入力変数と考えることができる。他の入力変数は異なるが、これはMRAは線形関係のみを解析するに対しFNNは非線形解析も可能であるためと考えられる。

つぎにFNNと重回帰分析の推定結果をFig.3に示す。両軸は規格化した値であり縦軸に推定値、横軸に実際の値を示す。対角線上に点が集約するほど精度が高いことになるが、FNNモデルはMRAモデルと比べてかなり精度よく推定できた。FNNの平均自乗誤差は、学習用(J_1)、評価用(J_2)とともにMRAより少なく、 J 値は約1/3になり、平均相対誤差は6.3%となった。これらの結果から、本手法では従来法であるMRAより少ない入力変数で単純なモデルが構築でき、より精度の高いモデルが構築できることが明らかになった。

Table.2 変数増加法により選択された変数

入力変数	FNN	重回帰式
	エアタンク風量（6H積算） COD 時間 エアタンク流入量（6H積算） MLSS（平均値） MLSS（6H積算）	エアタンク風量（6H積算） COD SS（6H積算） 余剰汚泥量 DO（6H積算） DO（2系出口） 総風量
		ORP（6H積算） 時間 放流水PH 余剰汚泥量（6H積算） 返送汚泥量（6H積算） ORP（平均）

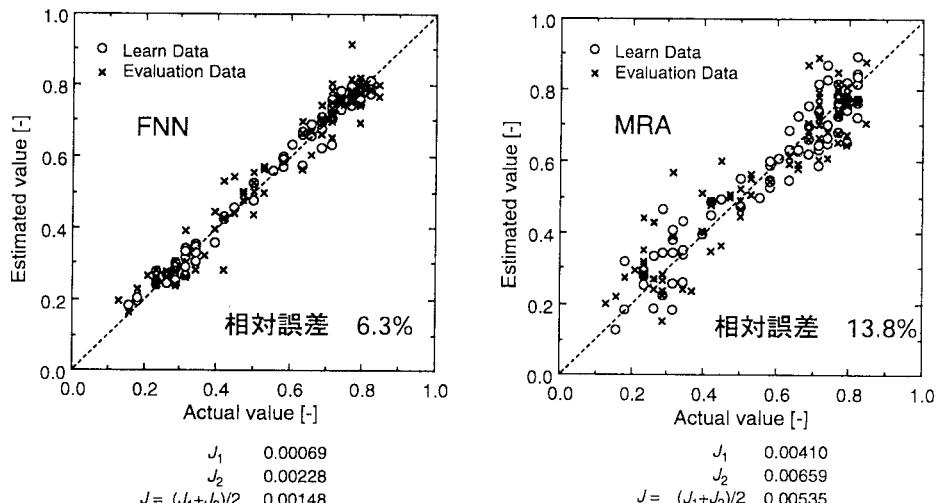


Fig.3 重回帰分析およびFNNの推定結果

3.2 シミュレーション結果

評価用データのみを用いてFNNでU処理場のシミュレーションを行った結果をFig.4に示す。全期間を通じてCODの急速な増加、減少も十分にシミュレーションできていることが分かる。また平均絶対誤差が0.13、相対誤差で約1%の精度で推定することができた。この誤差範囲では、運転管理の際のシミュレーションとしては十分な推定精度であると考えられる。

しかし実際にはU処理場のように1時間ごとに測定を行っておらず、1日に1回程度測定を行っているのが普通である。そこでつぎに、A処理場のデータを用いて同様の方法で放流水のCODの推定を行い、シミュレーションを行った。その結果をFig.5に示す。実際のプロセスの時間変化量から考えて、少なくとも1日に数点のデータが必要であるが、1日1点のデータでも平均絶対誤差が0.53、相対誤差で約5%精度であり、おおまかにCODの変動を推定することができ、FNNはこのような系に対しても適応が出来ることがわかった。

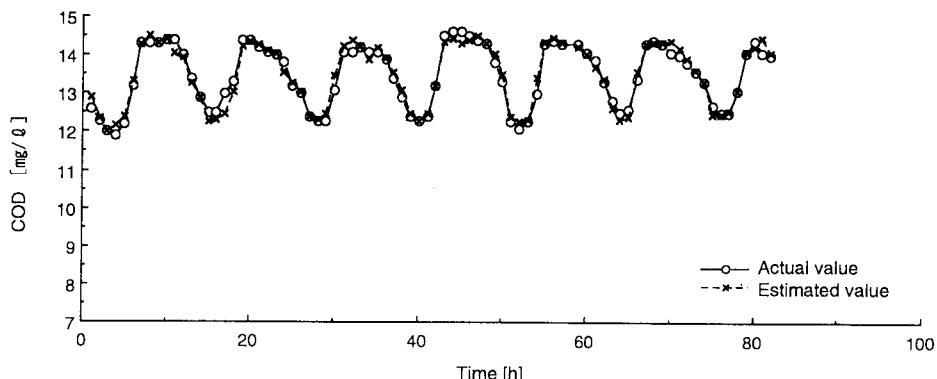


Fig.4 U処理場のシミュレーション結果

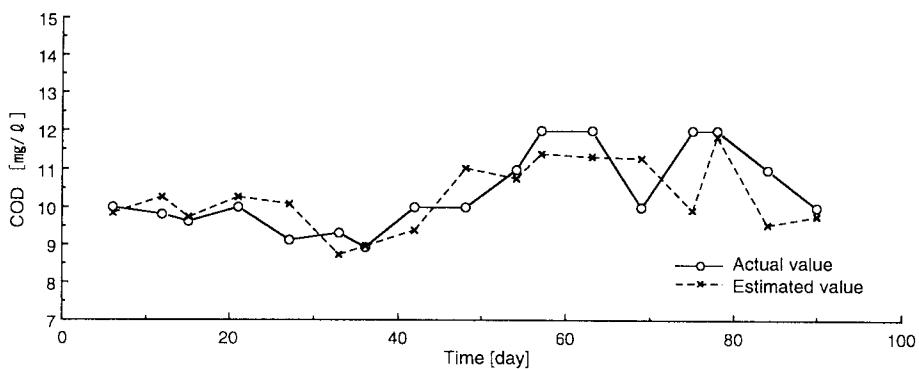


Fig.5 A処理場のシミュレーション結果

4.まとめ

演者らはこれまでに、知識工学的手法を用いた吟醸酒もろみ発酵プロセスの解析、制御³⁾を行い、生物プロセスシステムへの有効性を確かめてきた。今回、複数の微生物が影響を及ぼす放流水CODに対しFNNを用い精度の高いシミュレーターを構築することができた。このシミュレーターを用いれば、運転管理、運転支援の有効な手段になりえることが期待される。今後は季節ごとのルールの変化の解析を行うことで年間を通してガイドを作製する予定である。

また過去に本研究室で行った遺伝的アルゴリズム(GA)を用いた吟醸酒の品質モデリング⁴⁾と同様な方法で、出力変数から入力変数を計算することにより、目的のCODに制御するためのエアレーションタンクの風量や返送汚泥の量を求めることができ、最適運転の提案が可能となる。さらに、異なる処理場でこのような解析を行えば、選ばれた変数やルールから各処理場の流入水の水質や運転指針の特徴が明らかになると考えられるので、今後はこれらについて研究したい。

参考文献

- 1) Taizo Hanai, Akihiro Kakamu, Hiroyuki Honda, Takeshi Kobayashi et. al. : 計測自動制御学会論文集, 32, 1113-1120 (1996)
- 2) 堀川慎一, 吉橋 武, 内川嘉樹: 日本ファジイ学会誌, 4, 906-928 (1992) .
- 3) 本多裕之, 花井泰三, 小林 猛ほか: 生物工学, 74, 185-213 (1996)
- 4) 各務彰洋, 花井泰三, 本多裕之, 小林 猛: 生物工学, 73, 387-395 (1995)