
층간 연결에 의한 GMDH 알고리듬의 모델링 성능 향상

홍연찬*

Improvement of Modeling Capability of GMDH Algorithm with Interlayer Connection

Yeon Chan Hong*

본 논문은 2007년도 인천대학교 학술연구조성비 지원에 의하여 수행되었음

요약

복잡한 비선형 시스템을 모델링하기 위하여 GMDH(Group Method of Data Handling) 알고리듬을 사용할 수 있다. 기존의 GMDH 알고리듬은 정해진 절차에 의해 입력층부터 중간층들을 거쳐 출력층에서 시스템의 모델링 출력을 생성한다. 각 층의 출력은 전 층의 출력에 의해서만 생성된다. 그러나 입력들 중에서는 다른 입력들보다 모델링 결과에 더 큰 영향을 줄 수 있는 입력들이 있을 수 있다. 따라서 본 논문에서는 영향이 큰 입력들을 층간 연결하여 모델링 성능을 향상시키는 방법을 제안하였다. 제안된 알고리듬이 기존의 알고리듬보다 성능이 향상된 것을 컴퓨터 시뮬레이션을 통해 검증하였다.

ABSTRACT

The GMDH(Group Method of Data Handling) algorithm can be used to model the complex nonlinear systems. The traditional GMDH algorithm produces the output of the system model in the output layer through the input layer and the intermediate layers as the prescribed process. The outputs of each layer are produced only by the outputs of the former layer. However among the inputs there may be the inputs which can influence the modeling result more than the other inputs. Therefore in this paper the method which improve the modeling capability by interlayer connection of more influential inputs is proposed. The capability improvement of the proposed algorithm compared to the traditional algorithm is verified through computer simulation.

키워드

GMDH algorithm, nonlinear system, system model, interlayer connection, computer simulation

* 인천대학교 전자공학과

접수일자 2009. 04. 02

심사완료일자 2009. 05. 28

I. 서 론

GMDH는 1960년대 후반에 A. G. Ivakhnenko에 의해 고안되었다[1,2]. 입출력 데이터에 의한 시스템의 모델링을 위해 고안된 GMDH는 인식, 예측, 최적화, 제어를 위한 시스템 분석 및 설계에 사용된다. 복잡한 시스템의 모델링 문제는 그 시스템들의 특성이 비선형이고 차수가 크기 때문에 일반적으로 난해하다. 이러한 복잡한 시스템의 모델링에 우수한 성능을 나타내는 GMDH 구조의 기본 개념은 발견적 자기 구성(heuristic self-organization)에 기초를 두고, 그 결과로 생성되는 다항식 방정식은 Kolmogorov-Gabor 다항식[3]과 관련된다. GMDH의 구조는 각 층(layer)에서 유용한 데이터를 자체적으로 추출하는 한계값을 갖는 다층의 알고리듬을 통하여 정확성을 증가시키기 위해 해로운 정보를 제거하는 일종의 발견적 필터로 볼 수 있다[4].

GMDH 알고리듬의 기본 구조와 여러 가지 형태를 Farlow[5]가 잘 설명하고 있으며, GMDH 알고리듬의 개선 방법에 관한 연구들도 많은 연구자들에 의해 수행되었다[6,7]. Ivakhnenko[8]는 instrumental variable을 사용하여 모델링의 성능을 제고시켰고, Yoshimura[9]는 Akaike 정보 기준[10]을 사용한 RGMDH(Revised GMDH)를 제안하였다. Hayashi[11]는 확률적 회귀분석을 사용한 퍼지 GMDH를 제안하였다. 실제의 시스템에 GMDH를 응용한 사례도 많이 찾아 볼 수 있는데 Chao[12]가 생산 시스템을 GMDH로 모델링하였고, Chen[13]은 로봇에 GMDH를 응용하였다.

본 논문에서는 복잡한 비선형 시스템을 모델링하기 위하여 GMDH 알고리듬을 사용하였다. 기존의 GMDH 알고리듬은 정해진 절차에 의해 입력층부터 중간층들을 거쳐 출력층에서 시스템의 모델링 출력을 생성한다. 각 층의 출력은 전 층의 출력에 의해서만 생성된다. 그러나 입력들 중에서는 다른 입력들보다 모델링 결과에 더 큰 영향을 줄 수 있는 입력들이 있을 수 있다. 따라서 본 논문에서는 영향이 큰 입력들을 중간 연결하여 모델링 성능을 향상시키는 방법을 제안하였다. 제안된 알고리듬이 기존의 알고리듬보다 성능이 향상된 것을 컴퓨터 시뮬레이션을 통해 검증하였다.

II. 중간 연결에 의한 GMDH 알고리듬

GMDH 알고리듬은 시스템 제어 분야에 널리 응용되어 왔으며 최근 환경 및 경제 등의 시계열 함수 예측 분야의 모델링에 널리 응용되고 있다. GMDH 알고리듬의 모델도 다변량 회귀 모델로 대표되는 통계적 모델을 대상으로 하는 그림 1과 같은 시스템의 입출력 정보를 기초로 하여 근사 모델을 만드는 것이다.

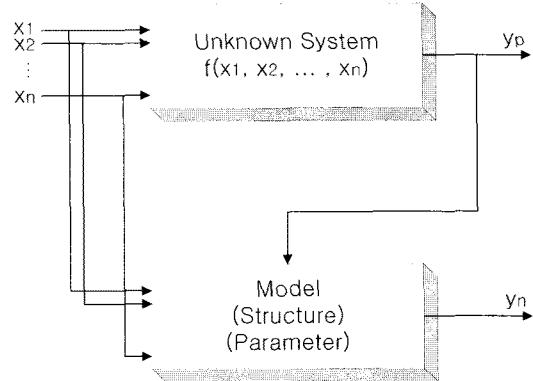


그림 1. GMDH 알고리듬을 위한 근사 모델.
Fig. 1. Approximate model for GMDH algorithm.

일반적으로 차분 방정식에 의한 비선형 다이내믹 시스템의 상태 방정식은 다음과 같다.

$$\begin{aligned} x(k+1) &= \Phi[x(k), u(k)] \\ y(k) &= \Psi[x(k)] \end{aligned} \quad (1)$$

이때, $x(k)$, $y(k)$, $u(k)$ 는 각각 상태, 출력, 입력을, $\Phi[\cdot]$ 와 $\Psi[\cdot]$ 는 비선형 함수를 나타낸다. 이와 같은 비선형 차분 방정식을 재구성하면 다음과 같은 식으로 나타낼 수 있다[14].

$$y(k+1) = f[y(k), y(k-1), \dots, y(k-n+1), u(k), \dots, u(k-m+1)] \quad (2)$$

이때 $f[\cdot]$ 는 비선형 함수이다.

GMDH는 입력 노드들의 집합으로 이루어져 있으며, 이 입력 노드들로부터 출력을 얻기 위하여 중간층들을 거치게 된다. 각 층에서의 노드들은 바로 전단계 층의 노

드들의 출력들로부터 두개씩을 취하여 출력을 만들어낸다. GMDH의 구조를 그림2에 나타내었다. 그림 2에서 $z_{s,t}$ 는 s번째 층과 t번째 노드의 출력을 나타내며 m은 입력의 개수이다. 두번째 층은 i개의 노드들로 구성되어 있는데, $i < \frac{m(m-1)}{2}$ 이고 $j < \frac{i(i-1)}{2}$ 이다. 이 부등식들이 성립하는 이유는 뒤에서 언급할 데이터 선택 기준에 의해 영향이 적은 데이터를 버리기 때문이다. 최종적으로 하나의 출력을 얻게 되는 과정도 데이터 선택 기준의 최소값에 의해 결정된다. 모든 층의 각각의 노드들의 출력은 GMDH 알고리즘의 일반적인 표현에 따라 다음 식과 같이 2차 방정식의 형태를 취하게 된다.

$$z_{s,t} = a_{s,t}z_{(s-1),u}^2 + b_{s,t}z_{(s-1),v}^2 + c_{s,t}z_{(s-1),u} + d_{s,t}z_{(s-1),v} + e_{s,t}z_{(s-1),u}z_{(s-1),v} + f_{s,t} \quad (3)$$

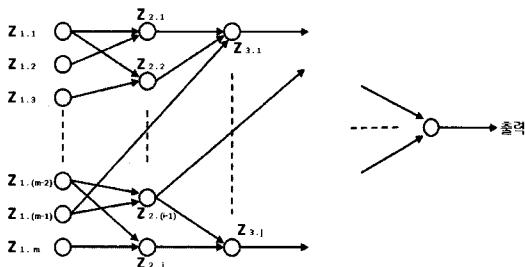


그림 2. 층간 연결에 의한 GMDH의 구조.

Fig. 2. Structure of GMDH with interlayer connection.

이때 $a_{s,t}$, $b_{s,t}$, $c_{s,t}$, $d_{s,t}$, $e_{s,t}$, $f_{s,t}$ 는 노드의 연결강도(connection weight)이고, 아래첨자 u와 v는 임의의 u번째와 v번째 노드를 가리킨다. $z_{(s-1),u}^2$ 와 $z_{(s-1),v}^2$ 는 벡터로서 각 요소들을 제곱한다는 것을 의미하고, $f_{s,t}$ 는 각 요소에 $f_{s,t}$ 를 더한다는 것을 의미한다. 다시 말해서, GMDH의 원리는 예를 들어 3번째 층으로 들어오는 i개의 입력들의 조합의 수(C_2^i)에 의해 서 다음 층의 노드 수가 결정되고 난 후, 이 노드들의 출력이 (3)식에 의해 각각 계산되며, 계산된 출력이 실제의 출력에 가까운가의 여부를 성능 기준에 의하여 판별한다는 것이다. 이처럼 각각의 층에서의 적합치 못한 노드들을 판별해내기 위해서는, 다음과 같이 원하는 최종 출력과 실제 노드 출력들 사이의 에

러를 계산하는 것이다.

$$r_{s,t} = |y(k) - (z_{s,t})_l| \quad (4)$$

여기서 $(z_{s,t})_l$ 은 s번째 층과 t번째 노드의 출력인 $z_{s,t}$ 벡터의 마지막 요소를 의미한다. 이 애러의 크기를 구하여 큰 애러를 가진 노드는 없애고 애러가 작은 노드들만을 가지고 앞서 설명한 과정들을 원하는 출력을 얻을 때 까지 반복하게 되는 것이다. 그리고 이 알고리즘은 일반적으로 사용되고 있는 신경망 구조와는 달리 중간층의 수와 노드들의 수가 미리 정해지는 것이 아니다.

일반적인 GMDH 알고리듬에서는 데이터를 취사선택하는 기준으로서 미리 정한 일정한 값 R 을 애러 $r_{s,t}$ 와 비교하여 $r_{s,t}$ 가 R 보다 작으면 그 노드의 출력을 취하고 $r_{s,t}$ 가 R 보다 크면 그 노드의 출력은 버린다. 그러나 이러한 방식을 사용하면, 층이 증가함에 따라서 노드의 출력이 실제의 출력에 점점 가까워지기 때문에 잔존하는 노드의 수가 점점 증가한다. 따라서 알고리듬의 계산량이 증가하는 단점이 발생한다. 그러므로 본 논문에서는 기준 R 을 순차적으로 감소시킴으로써 계산량의 과다를 방지하는 방법을 사용한다.

우선 알고리듬의 종료 방법을 설명하면 각 층에서의 애러의 최소값 $RMIN_s$ ($s=1, 2, \dots$)를 구하여 이 $RMIN_s$ 가 최소가 되는 층에서 알고리듬을 종료한다. 그러므로 s층에서 최소의 애러를 갖는 노드의 출력이 실제의 출력의 추정치가 된다.

일반적인 GMDH 알고리듬에서는 애러가 R 보다 작은 노드들이 모두 선택되며 층이 증가함에 따라서 $RMIN_s$ 와 R 사이의 간격이 커지므로 노드의 수가 크게 증가한다. 따라서 본 논문에서는 노드의 수가 크게 증가하는 것을 막기 위해 다음과 같은 기준을 설정한다.

$$R_s = RMIN_s + \delta \quad (5)$$

여기서 δ 는 미리 정한 일정한 값이다. 선택 기준을 (5)식과 같이 정함으로써 노드의 수가 크게 증가하는 것을 막을 뿐만 아니라 데이터를 $RMIN_s$ 에 대하여 균등화

게 선택할 수 있다는 것을 알 수 있다.

III. 비선형 시스템의 모델링

(2)식으로 나타낸 비선형 다이내믹 시스템을 모델링하기 위한 GMDH 알고리듬을 다음과 같이 3 단계로 나누어 설명할 수 있다.

[단계1] 변수벡터의 구성

(3)식에 의하여 k 순간에서 s 층의 t 번째 노드의 출력 $z_{s,t}(k)$ 를 만들어 내며 다음식과 같이 간단하게 표현할 수 있다.

$$z_{s,t}(k) = X_{s-1} \Theta_s \quad (6)$$

이 때,

$$\begin{aligned} X_{s-1} &= [z_{(s-1),u}^2(k); z_{(s-1),v}^2(k); z_{(s-1),u}(k); \\ &\quad z_{(s-1),v}(k); z_{(s-1),u}(k)z_{(s-1),v}(k); 1] \\ \Theta_s &= [a_{s,t}; b_{s,t}; c_{s,t}; d_{s,t}; e_{s,t}; f_{s,t}]^T \end{aligned}$$

여기서 X_{s-1} 은 차수가 $p \times 6$ 인 데이터 행렬로서 두 벡터 입력 $z_{(s-1),u}(k)$ 와 $z_{(s-1),v}(k)$ 를 합성한 것이다. $(k+1)$ 인 순간에 첫번째 층의 입력과 출력은 그림 3과 같다. GMDH로 비선형 다이내믹 시스템을 모델링 할 때 인가되는 입력 벡터는 $(m+n)$ 개이다. 각 벡터의 요소는 p 개이며 임의로 정해진다. p 의 크기에 따라서 인가되는 데이터의 양이 결정된다. (6)식은 Θ_s 와 함께 2차 방정식을 만들어낸다. 이 때 $z_{s,t}(k)$ 를 얻기 위해서는, 먼저 (6)식을 풀어 계수 벡터인 연결장도 Θ_s 를 얻어야 한다. 각 노드의 출력 $z_{s,t}(k)$ 가 최종적으로 시스템의 출력 $y(k)$ 가 되도록 하는 것이 이 알고리듬의 목적 이므로 그 일반식은 다음과 같다.

$$\begin{aligned} \theta_s &= (X_{s-1}^T X_{s-1})^{-1} X_{s-1}^T y(k) \quad \text{if } p \geq 6 \\ &= X_{s-1}^T (X_{s-1} X_{s-1}^T)^{-1} y(k) \quad \text{if } p < 6 \end{aligned} \quad (7)$$

[단계 2] 영향이 적은 데이터의 제거

앞서 설명했듯이, 단계 1에서 구해진 모든 노드들의 출력들이 다음 층으로 전달되는 것은 아니다. 즉 적자 생존의 원칙을 적용해야 한다. 일반적인 GMDH에서는 출력과 새로 생성된 데이터를 훈련 부분과 검사 부분으로 나누어야 한다. 그래서 출력과 생성된 데이터의 훈련부분 과정에서 구해진 평균제곱에러에 의해 필요없는 노드들을 제거한다. 이를 수행하는 방법들에는 여러 가지가 제시되고 있으나 본 논문에서는 비선형 시스템을 동적으로 모델링하고자 하므로 그림 3의 모든 데이터를 훈련 부분에서 사용하고 (4)식과 같이 데이터 벡터의 마지막 요소를 검사 부분으로 사용하였다.

$r_{s,t}$ 값의 증가순으로 s 층의 모든 $z_{s,t}(k)$ 를 다시 정렬시킨다. 그리고 (5)식으로 구한 기준값 R_s 보다 큰 값을 갖는 노드들을 제거한다. 그리고 제거되지 않은 변수 $z_{s,t}(k)$ 들을 $(s+1)$ 층의 입력으로 사용한다.

[단계 3] 최적성의 시험

이 단계에서는 훈련을 계속할지를 판별하기 위하여, 단계 2에서 계산된 $r_{s,t}$ 들의 최소값 $RMIN_s$ 를 전 단계의 $RMIN_{s-1}$ 과 비교하는 것이다. $RMIN_s < RMIN_{s-1}$ 이면 단계 1과 2를 반복하고, $RMIN_s \geq RMIN_{s-1}$ 이면 $RMIN_{s-1}$ 에 해당하는 $z_{(s-1),t}(k)$ 를 출력의 추정치 $\hat{y}(k)$ 로 보고 모든 훈련을 끝내게 되는 것이다. 그러면 이 $z_{(s-1),t}(k)$ 는 Ivakhnenko 다항식[5]이 된다.

결국, 본 논문의 GMDH 알고리듬과 전형적인 GMDH 알고리듬의 차이점은, 단계 2에서 전형적인 GMDH 알고리듬은 일정한 R_s 를 기준값으로 설정하지만 본 논문의 GMDH 알고리듬은 (5)식으로부터 R_s 를 구하므로 기준값이 점차 감소하게 되어 비교적 큰 에러를 갖는 노드들을 제거할 수 있다는 것이다. 또한, 다이내믹 시스템을 모델링하기 위하여 그림 3과 같이 입력력 데이터를 윈도우(window)화하는 적용 방법을 사용하였다.

출 력		입 력						
$y(k-p+2)$		$u(k-p+1)$	$u(k-p)$	\dots	$u(k-m-p+2)$	$y(k-p+1)$	$y(k-p)$	\dots
$y(k-p+3)$		$u(k-p+2)$	$u(k-p+1)$	\dots	$u(k-m-p+3)$	$y(k-p+2)$	$y(k-p+1)$	\dots
\vdots		\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
$y(k)$		$u(k-1)$	$u(k-2)$	\dots	$u(k-m)$	$y(k-1)$	$y(k-2)$	\dots
$y(k+1)$		$u(k)$	$u(k-1)$	\dots	$u(k-m+1)$	$y(k)$	$y(k-1)$	\dots

그림 3. GMDH의 입력과 출력
Fig. 3. Input and output of GMDH

IV. 데이터 가중율을 적용한 알고리듬

비선형의 특성을 가진 시계열 함수는 일반적으로 과거의 훈련 데이터 보다는 최근의 훈련 데이터가 현재 또는 미래의 예측에 많은 기여를 하게 된다. 하지만 전형적인 GMDH 알고리듬에서는 과거의 훈련 데이터와 최근의 훈련 데이터가 동일한 비율로 훈련에 기여하게 된다. 이는 GMDH 알고리듬의 특성상 여러 $r_{s,t}$ 의 허용한계치인 R 이 하나의 값으로 사전에 정의되고 모든 과거와 현재 데이터의 최적성 검사에 하나의 R 을 기준으로 하기 때문이다. 따라서 본 논문에서는 부분 표현식과 검사 데이터와의 예러 $r_{s,t}$ 에 가중치를 주고자 한다. 즉 과거의 데이터일수록 $r_{s,t}$ 를 감소시켜 훈련 비율을 줄이고, 최근의 데이터일수록 $r_{s,t}$ 를 증가시켜 훈련 비율을 높이는 방법을 사용한다.

전형적인 GMDH 알고리듬의 성능 기준(Regularity Criterion)에 (8)식 형태의 지수 함수를 추가하여 최근의 데이터 일수록 훈련 데이터의 비율을 높이고자 한다.

$$C = \frac{2}{1 + \exp(a - 2ak/l)} \quad (8)$$

(8)식은 과거의 데이터의 비율은 줄이고 최근의 데이터의 비율을 높이기 위한 가변 상수로서 여기서 k 는 훈련 데이터의 순서를 가리키며, $k=1$ 이 되는 시점이 가장 오래된 데이터가 적용되는 시점이며, $k=l$ 인 시점이

가장 최근의 데이터가 된다. a 는 데이터 가중율을 결정하는 상수이다. 즉 a 가 커질수록 과거의 데이터의 비율은 보다 작아지고 최근의 데이터의 비율이 보다 커지게 된다. 단, $a=0$ 일 때 C 는 k 에 상관없이 1이 되므로 원래의 성능 기준에 적용되었을 때 영향을 주지 않는다. 입력 변수들의 변화에 따른 데이터 가중 상수 C 의 출력 그래프는 그림 4와 같다.

(9)식은 데이터 가중 상수 C 를 GMDH 알고리듬의 성능 기준에 적용한 데이터 가중 성능 기준이 된다.

$$r_j^2 = C \frac{\sum_{i=nt+1}^{2nt} (y_i - z_{ij})^2}{\sum_{i=nt+1}^{2nt} y_i^2}, \quad j = 1, 2, \dots, \binom{m}{2} \quad (9)$$

이때,

$$C = \frac{2}{1 + \exp(a - 2a(i-nt)/nt)}$$

(9)식에서 nt 는 훈련 데이터의 수를 나타내고, 가장 오래된 훈련 데이터일 경우 데이터 가중 상수 C 에서의 $i-nt=1$ 이 되어 r_j 값을 데이터 가중율 a 의 비율만큼 감소시키게 되고, i 가 증가함에 따라 계속해서 데이터 가중율이 증가하다가 가장 최근의 데이터일 경우 $i-nt=nt$ 가 되어 r_j 를 데이터 가중율 a 의 비율만큼 증가시키게 된다.

일반적으로 신경망이나 GMDH 알고리듬을 이용한 시계열 함수 예측의 경우, 허용 에러 기준을 크게 설정하면 계산량은 감소하지만 에러율이 증가하게 되고, 허용 에러 기준을 작게 설정하면 계산량은 증가하지만 에러율이 감소하게 된다. 따라서 최적의 데이터 가중율 a 를 찾는 것이 중요하다.

V. 시뮬레이션 결과

수정된 GMDH 알고리듬의 성능을 분석하기 위한 컴퓨터 시뮬레이션을 위해 다음과 같은 비선형 시스템을 설정하였다.

$$y(k+1) = \frac{y(k)}{1+y^2(k)} + u^3(k) \quad (10)$$

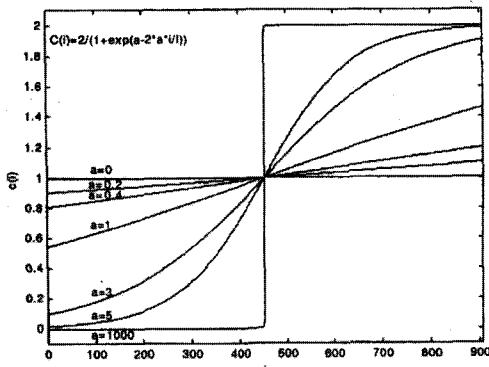


그림 4. i 에 대한 가중 상수 C .
Fig. 4. Weighting constant C versus i .

그림 5는 전형적인 GMDH 알고리듬에 의한 시뮬레이션 결과를 나타낸다. 그림에서 알 수 있듯이 변동이 심한 부분인 5 스텝과 22 스텝 지점에서 모델링 출력 $\hat{y}(k)$ (그림에서는 $y_h(k)$)가 실제의 출력 $y(k)$ 를 잘 추종하고 있지 않다. 변동이 심한 부분에서는 과거의 경향보다는 최근의 경향이 더 영향을 주기 때문에 과거의 데이터가 모델링 결과를 악화시키기 때문인 것을 알 수 있다.

그림 6은 본 논문에서 제안한 총간 연결과 데이터 가중율을 적용한 GMDH 알고리듬에 의한 시뮬레이션 결

과를 나타낸다. 총간 연결을 임의로 할 수 있으나 본 시뮬레이션에서는 바로 직전의 데이터가 현재의 모델링 출력에 가장 큰 영향을 줄 것으로 보아 바로 직전의 입력과 출력 데이터를 모든 층에 총간 연결하였다. 그 결과로 변동이 심한 부분인 5 스텝과 22 스텝 지점에서 모델링 출력이 실제의 출력을 에러율 0.0087로 잘 추종하고 있는 것을 알 수 있다.

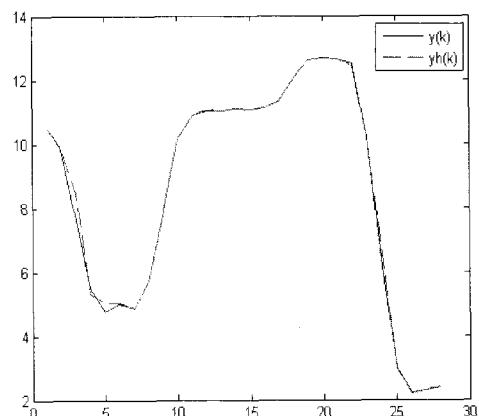


그림 5. 전형적인 GMDH 알고리듬의 모델링 출력 비교
Fig. 5. Comparison of modeling output by conventional GMDH algorithm.

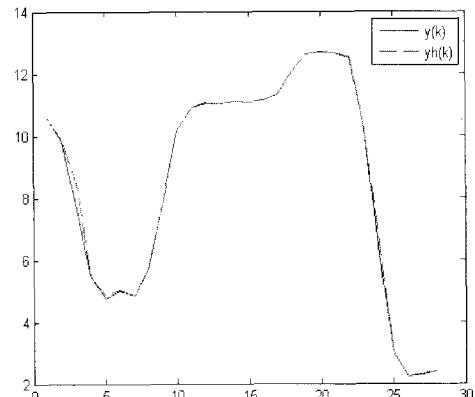


그림 6. 총간 연결과 데이터 가중율을 적용한 GMDH 알고리듬의 모델링 출력 비교
Fig. 6. Comparison of modeling output by GMDH algorithm with interlayer and data weighting rate.

전형적인 GMDH 알고리듬의 모델링 평균 에러는 0.0732이고 층간 연결과 데이터 가중율을 적용한 GMDH 알고리듬의 모델링 평균 에러는 0.0552로 측정되었다. 따라서 본 논문에서 제안한 GMDH 알고리듬은 평균 에러를 0.018 감소시키는 결과를 가져옴으로써 24.6%의 모델링 성능 향상을 이루었다.

VI. 결론

복잡한 비선형 시스템의 입출력 데이터만을 가지고 시스템을 모델링하는 방법의 하나인 GMDH 알고리듬에서 중요한 데이터를 층간 연결하여 그 영향을 크게 해 줄 수 있는 층간 연결 알고리듬과 최근 데이터가 모델링 결과에 더 영향을 줄 수 있는 데이터 가중율을 적용한 GMDH 알고리듬을 제안하여 다이내믹 시스템 모델링의 성능을 개선하고자 하였다. 제안된 알고리듬을 컴퓨터 시뮬레이션을 통하여 입증하였다.

컴퓨터 시뮬레이션 결과에 의하면 전형적인 GMDH 알고리듬보다 본 논문에서 제안한 GMDH 알고리듬이 더 우수한 특성을 갖는다는 것을 알 수 있었다. 모델링 성능이 24.6 % 정도 개선되었으며 중요한 데이터를 더 적절히 층간 연결함으로써 더 많은 모델링 성능 개선 효과를 가져올 수도 있을 것으로 기대된다.

참고문헌

- [1] A. G. Ivakhnenko, "Polynomial theory of complex systems," IEEE Trans. Syst. Man Cybern, vol. SMC-1, pp. 364-378, 1971.
- [2] A. G. Ivakhnenko, "Heuristic self-organization in problems of engineering cybernetics," Automatica, vol. 6, pp. 207-219, 1970.
- [3] R. A. Roy and J. Sherman, "A learning technique for Volterra series representation," IEEE Trans. Automat. Contr., vol. AC-12, pp. 761-764, 1967.
- [4] T. Nishikawa and S. Shimizu, "The characteristics of a biased estimator applied to the adaptive GMDH," Mathl. Comput. Modelling, vol. 17, no.1, pp. 37-48, 1993.
- [5] S. J. Farlow, *Self-Organizing Methods in Modelling : GMDH Type Algorithms*. New York : Marcel Decker Inc., 1984.
- [6] N. Y. Nikolaev and H. Iba, "Polynomial harmonic GMDH learning networks for time series modeling," Neural Networks, vol. 16, pp. 1527-1540, 2003.
- [7] S.-P. Lo and Y.-Y. Lin, "Application of abductive polynomial network and grey theory to drill flank wear prediction," Applied Artificial Intelligence, vol. 18, pp. 713-733, 2004.
- [8] A. G. Ivakhnenko and A. A. Zholnarskiy, "Estimating the coefficients of polynomials in parametric GMDH algorithms by the improved instrumental variables method," Soviet Automatic Control, vol. 25, no.3, pp. 25-32, 1992.
- [9] T. Yoshimura, R. Kiyozumi, K. Nishino, and T. Soeda, "Application of revised GMDH algorithms to the prediction of air pollutant concentrations," Proc. 23rd IFAC World Congr., vol. XXIII, pp. 13-17, Kyoto, Japan, Aug. 1981.
- [10] H. Akaike, "A new look at the statistical model identification," IEEE Trans. Automat. Contr. vol. AC-19, pp. 716-723, 1974.
- [11] I. Hayashi and H. Tanaka, "The fuzzy GMDH algorithm by possibility models and its application," Fuzzy Sets and Systems, vol. 36, pp. 245-258, 1990.
- [12] P. Y. Chao, P. M. Ferreira, and C. R. Liu, "Applications of GMDH-type modeling in manufacturing," Journal of Manufacturing Systems, vol. 7, no.3, pp. 241-253, 1988.
- [13] C. L. P. Chen and A. D. McAulay, "Robot Kinematics learning computations using polynomial neural networks," Proc. 1991 IEEE Int. Conf. on Robotics and Automation, pp. 2638-2643, Sacramento, California, Apr. 1991.
- [14] K. S. Narendra and K. Parthasarathy, "Identification and control of dynamical systems using neural networks," IEEE Trans. Neural Networks, vol. 1, no. 1, pp. 4-27, Mar. 1990.

저자소개



홍연찬(Yeon Chan Hong)

1983년 서울대학교 전자공학과 졸업.
1985년 동 대학원 석사.
1989년 동 대학원 박사.
1987년 ~ 1990년 LG정보통신(주)
연구소 선임연구원.

1990년 ~ 1992년 순천향대학교 전자공학과 전임강사.

1992년 ~ 현재 인천대학교 전자공학과 교수

※ 관심분야: GMDH, RFID, 신경망, 제어 시스템 설계