

# 데이터 가중 성능을 갖는 GMDH 알고리즘 및 전력 수요 예측에의 응용

## GMDH Algorithm with Data Weighting Performance and Its Application to Power Demand Forecasting

신재호, 홍연찬\*

(Jae Ho Shin and Yeon Chan Hong)

**Abstract :** In this paper, an algorithm of time series function forecasting using GMDH(group method of data handling) algorithm that gives more weight to the recent data is proposed. Traditional methods of GMDH forecasting gives same weights to the old and recent data, but by the point of view that the recent data is more important than the old data to forecast the future, an algorithm that makes the recent data contribute more to training is proposed for more accurate forecasting. The average error rate of electric power demand forecasting by the traditional GMDH algorithm which does not use data weighting algorithm is 0.9862 %, but as the result of applying the data weighting GMDH algorithm proposed in this paper to electric power forecasting demand the average error rate by the algorithm which uses data weighting algorithm and chooses the best data weighting rate is 0.688 %. Accordingly in forecasting the electric power demand by GMDH the proposed method can acquire the reduced error rate of 30.2 % compared to the traditional method.

**Keywords :** GMDH algorithm, data weighting, electric power demand forecasting, data weighting rate

### I. 서론

경제지수 또는 전력수요 예측을 위한 시계열 함수는 일반적으로 여러 가지 요인에 의해 불규칙하게 변동되고, 노이즈가 많은 특성이 있어 정확하게 예측하는 데 어려움이 있다. 현재까지 대부분의 시계열 함수 예측은 신경회로망, 퍼지이론 등과 같은 인공지능 기법을 적용한 방법이 국내 외적으로 활발히 연구되고 있다[1,2]. 특히, 예측모델의 구성이 용이하고 기존의 시계열해석법이나 회귀분석법에 비해 우수하다고 평가되고 있는 신경회로망 기법이 주류를 이루고 있으며 여러 가지 모델이 제시되고 있다. 그러나 신경회로망을 이용한 수요예측 기법은 예측을 위한 데이터를 모두 처리하므로 많은 계산량으로 인해 장기적인 예측에는 계산 시간이 많이 소요된다는 단점이 있다. 그러므로 기존 단점을 보완하여 데이터의 효율적인 활용과 정확성에서 우수한 특성을 보이는 GMDH(Group Method of Data Handling) 알고리즘을 적용한 연구가 진행되고 있다[3,4].

본 논문에서 이용한 GMDH 알고리즘에 관한 현재의 연구동향은 다음과 같다. Yoshimura는 부분표현식의 선택에 AIC(Akaike's Information Criterion)를 이용한 개량형 GMDH 알고리즘을 이용하여 산소 농도, 풍속, 풍향을 입력으로 하여 공기 오염 농도의 예측 모델을 구성하였다[5]. Nishikawa는 기업에 있어서 이전의 판매 실적값과 평균값을 이용하여 판매 예측값 모델을 구하여 생산, 판매, 재고 계획업무

에 GMDH 알고리즘을 적용하였다[6]. Ann은 화력발전량, 원유가, 환율을 독립변수로 이용하여 석유소비량을 예측하는 데 GMDH 알고리즘을 이용하였다[7]. Lee는 주가예측의 정확성을 높이기 위하여 GMDH 알고리즘을 이용함으로써 주식투자 전략을 위한 의사 결정과정에 보다 더 유용한 정보를 제공할 수 있도록 하였다[8]. 이와 같이 GMDH 알고리즘은 어떠한 비선형 시스템에 대한 모델링과 예측에 강점을 보이고 있다.

본 논문에서는 여러 가지 요인에 의하여 비선형적인 변동 특성을 보이는 전력 수요 예측에 GMDH 알고리즘을 이용하였다. 그리고, GMDH 알고리즘을 적용한 시계열 함수 예측에 있어 최근의 데이터일수록 예측에 많은 기여를 하도록 하는 알고리즘을 제안하였다. 이는 GMDH를 이용한 시계열 함수 예측에 처음으로 시도되는 방법으로서 전형적인 GMDH 알고리즘을 이용한 예측 방법에서는 과거와 최근의 데이터를 동일한 비율로 적용하여 훈련을 하였으나 최근의 데이터 일수록 현재 또는 미래의 예측에 있어 더 많은 영향을 미치게 된다는 점을 감안하여 최근의 데이터 일수록 훈련에 기여하는 비율을 높여 보다 정확한 예측을 하도록 하기 위해서이다[9].

### II. 데이터 가중율을 적용한 GMDH 알고리즘

#### 1. GMDH 알고리즘

GMDH 알고리즘은 Ivakhnenko[10]에 의해서 제안된 이후 시스템 제어 분야에 널리 응용되어 왔으며 최근 환경 및 경제 등의 시계열 함수 예측 분야의 모델링에 널리 응용되고 있다. GMDH 알고리즘의 모델도 다변량 회귀 모델로 대표되는 통계적 모델을 대상으로 하는 그림 1과 같은 시스템의 입출력 정보를 기초로 하여 근사 모델을 만드는 것이다.

\* 책임저자(Corresponding Author)

논문접수 : 2005. 12. 13., 채택확정 : 2006. 3. 21.

신재호, 홍연찬 : 인천대학교 전자공학과

(sjh5117@hotmail.com/yehong@incheon.ac.kr)

※ 본 논문은 2004년도 인천대학교 학술연구조성비 지원에 의하여 수행되었음.

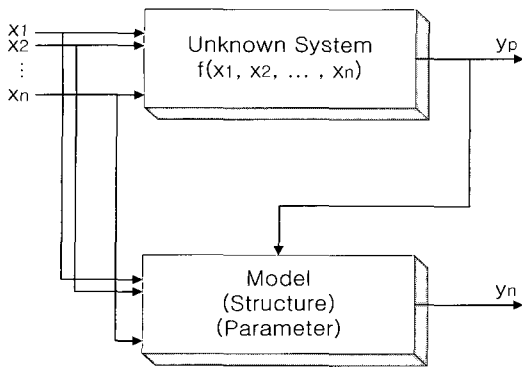


그림 1. GMDH 알고리즘을 위한 근사 모델.  
Fig. 1. Approximate model for GMDH algorithm.




그림 2. GMDH 알고리즘의 다단계 구조.  
Fig. 2. Multi-level structure of GMDH algorithm.

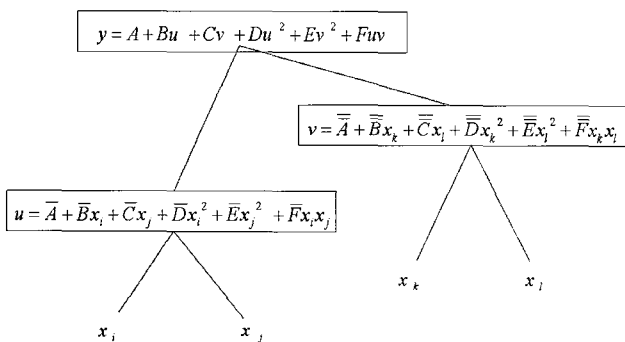


그림 3. 변수 전파의 구조.  
Fig. 3. Structure of variable propagation.

GMDH 알고리즘은 그림 2와 같이 다단계(multi-layered) 적 구조를 이루며 각 단계의 입력 데이터로부터 비선형 변형을 하는데, 이는 통상 그림 3과 같이 2개의 선정된 변수의 2차 다항식을 이룬다[11].

일반적으로 비선형 함수의 입출력 관계는 (1)과 같이 Volterra 급수로서 표현될 수 있다.

$$\begin{aligned} \psi(t) = & \int_0^t h_1(\tau_1)x(t-\tau_1)d\tau_1 \\ & + \int_0^t \int_0^t h_2(\tau_1, \tau_2)x(t-\tau_1)x(t-\tau_2)d\tau_1 d\tau_2 \\ & + \int_0^t \int_0^t \int_0^t h_3(\tau_1, \tau_2, \tau_3)x(t-\tau_1)x(t-\tau_2)x(t-\tau_3)d\tau_1 d\tau_2 d\tau_3 \\ & + \dots \end{aligned} \quad (1)$$

(1)을 이산형 다항식으로 표현하면 다음 식과 같은 Kolmogrov-Gabor의 다항식이 된다.

$$\Phi = a_0 + \sum_i^N a_i x_i + \sum_i^N \sum_j^N a_{ij} x_i x_j + \sum_i^N \sum_j^N \sum_k^N a_{ijk} x_i x_j x_k + \dots \quad (2)$$

(2)에서 입력은  $x_i = x(t-iT)$  이고 입력  $x(t)$ 의  $i$ 스텝 지연된 입력이며  $T$ 는 샘플링 시간(sampling time)이다. (2)의 회귀추정 문제에서 모델구조를 모를 경우 입력계수  $N$ 이 4인 경우만 하더라도 추정해야 할 계수는 70개항이 되고, 그에 따라 가능한 중회귀 구조의 수는 매우 많아진다[7]. 이와 같은 계산상의 어려움을 피하기 위해 모델구조를 자기 조직화(self organizing)하는 GMDH 알고리즘이 제시되었다.

시스템의 입력변수가  $x_1, x_2, x_3, \dots, x_N$ 의  $N$  개일 때 예측 모델의 출력을  $y_m$ 이라고 하면 예측 모델을 위한 일반 함수  $f$ 를 완전표현식이라 하고 (3)과 같이 나타낸다.

$$y_m = f(x_1, x_2, x_3, \dots, x_N) \quad (3)$$

일반적인 회귀 모델과 GMDH 알고리즘 모델의 가장 큰 차이점은 완전표현식  $f$ 의 구성을 결정하는 데 있어서 입력 데이터 간의 연결 강도와 취사선택을 자기 조직화 원리에 의하여 수행한다는 것이다.

기본적인 GMDH 알고리즘은 (2)에서 2변수 2차 다항식을 선택하는 경우이며 (4)와 같이 나타낸다.

$$\begin{aligned} z_{mn} = & G(x_i, x_j) \\ = & A + Bx_i + Cx_j + Dx_i x_j + Ex_i^2 + Fx_j^2 \end{aligned} \quad (4)$$

여기서  $z_{mn}$ 은  $m$ 번째 세대의  $n$ 번째 다항식의 값이다. 실제의 출력 데이터  $y$ 와  $z_{mn}$ 의 에러를 최소화하는 최소자승법을 이용하여 연결 강도  $A, B, C, D, E, F$ 를 구할 수 있다. (4)와 같은 부분표현식으로 여러 층을 거듭하여 각 층에서 최적인 부분표현식을 선택함으로써 원하는 대상의 식별모델을 찾아내며, 이 과정을 통한 완전표현식 (3)을 자기 조직화 원리에 의하여 다음 순서로 결정한다.

단계 1: 임의의 2개의 입력변수의 조합으로 만들어진 아래의 식들을 시스템의 출력  $y_p$ 에 근사하도록 결정한다.

$$\begin{aligned} z_{11} = & G(x_1, x_2), z_{12} = G(x_2, x_3), \\ \dots, z_{1s} = & G(x_{N-1}, x_N) \end{aligned} \quad (5)$$

단계 2: 앞 단계의  $z_{11}, z_{12}, \dots, z_{1s}$ 를 입력으로 하여 아래의 식들을 시스템의 출력  $y_p$ 에 근사하도록 결정한다.

$$z_{i1} = G(z_{11}, z_{12}), z_{i2} = G(z_{12}, z_{13}), \dots, z_{ip} = G(z_{1(s-1)}, z_{1s}) \quad (6)$$

여기서  $i$ 는 단계 2의 반복 횟수에 1을 더한 값이다.

단계 3: 단계 2에서 구한 함수  $G$ 를 부분표현식이라 부르고 이 식을 검사 데이터인 실제의 출력과 (7)에 의해 오차를 계산하여 오차가 적은 순서로  $r_j < R$ 인 부분표현식을 선택한다. 통상 그 수는 입력변수  $x_N$ 의 개수  $N$ 보다 적게 한다.




그림 4. GMDH 알고리즘의 종료 방법.

Fig. 4. Stopping method of GMDH algorithm.

$$r_j^2 = \frac{\sum_{i=nt+1}^n (y_i - z_{ij})^2}{\sum_{i=nt+1}^n y_i^2}, \quad j = 1, 2, \dots, \binom{m}{2} \quad (7)$$

여기서  $i = nt+1$ 부터 합을 구하는 것은  $nt$ 까지의 데이터는 훈련용이고  $nt+1$ 부터의 데이터를 검사용으로 사용한다는 의미이며,  $z_{ij}$ 는  $i$  번째 데이터들로  $j$  번째 변수 조합으로 회귀분석한 결과치이다. 이 단계에서 얻은 부분표현식 중에서  $r_j < R$  인 것만 다음 단계의 입력 변수로 활용된다.  $R$  은  $r_j$  의 허용한계치이며 사전에 사용자가 정의 한다[11].

단계 4: 단계 3에서 얻은  $r_j$  의 최소값인  $RMIN_s$ 를 전 단계의  $RMIN_{s-1}$ 과 비교하여 에러가 커질 경우 혹은 더 이상의 개선이 일어나지 않을 경우 계산을 중지하며, 그렇지 않을 경우 단계 2부터 다시 반복된다. 이 과정을 그림 4에 나타내었다[11].

이 단계에서 계산된 식을 최종 식별된 완전표현식  $y_n$ 으로 정하며 최초 단계의 입력변수  $x_1, x_2, x_3, \dots, x_N$ 의 다차 다항식으로 Ivakhnenko Polynomial[10]이라고 하며 (8)과 같다.

$$y_n = a + \sum_{i=1}^m b_i x_i + \sum_{i=1}^m \sum_{j=1}^m c_{ij} x_i x_j + \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m d_{ijk} x_i x_j x_k + \dots \quad (8)$$

2. 데이터 가중율을 적용한 알고리즘

비선형의 특성을 가진 시계열 함수는 일반적으로 과거의 훈련 데이터 보다는 최근의 훈련 데이터가 현재 또는 미래의 예측에 많은 기여를 하게 된다. 하지만 전형적인 GMDH 알고리즘에서는 과거의 훈련 데이터와 최근의 훈련 데이터가 동일한 비율로 훈련에 기여하게 된다. 이는 GMDH 알고리즘의 특성상 에러  $r_j$ 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 에러  $r_j$ 에 가중치를 주고자 한다. 즉 과거의 데이터일수록  $r_j$ 를 감소시켜 훈련 비율을 줄이고, 최근의 데이터일수록  $r_j$ 를 증가시켜 훈련 비율을 높이는 방법을 제안한다.

전형적인 GMDH 알고리즘의 성능 기준(regularity criterion)인 (3)에 (9)형태의 지수 함수를 추가하여 최근의 데이터 일수록 훈련 데이터의 비율을 높이고자 한다.

$$C = \frac{2}{1 + \exp(a - 2ak/l)} \quad (9)$$




그림 5.a에 대한 가중 상수 C.

Fig. 5. Weighting constant C versus a.

(9)는 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 5와 같다.

(10)은 데이터 가중 상수  $C$ 를 GMDH 알고리즘의 (7)에 적용한 데이터 가중 성능 기준이 된다.

$$r_j^2 = C \frac{\sum_{i=nt+1}^n (y_i - z_{ij})^2}{\sum_{i=nt+1}^n y_i^2}, \quad j = 1, 2, \dots, \binom{m}{2} \quad (10)$$

이때,

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

(10)에서  $nt$ 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 알고리즘을 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.

III. 시뮬레이션 결과

데이터 가중율을 적용한 GMDH 알고리즘과 전형적인 알고리즘을 전력 수요 예측[12]에 적용하여 그에 따른 에러율 차이를 검토하고자 한다. 전력 수요량을 예측하기 위하여 1991년 1/4 분기부터 2001년 1/4 분기까지 전력 수요량에 영향이 가장 많은 GDP, 수출액, 수입액, 경제활동 인구, 취업자 수, 석유 소비량, 평균 기온을 입력으로 사용하였다[12].

장기 예측의 경우에 대하여 제안한 GMDH 알고리즘의 예측 정확도를 입증하기 위해서 1991년 4/4 분기부터 1993년 4/4 분기까지 9개의 분기를 입력 데이터로 하여 1999년 1/4 분기부터 2001년 1/4 분기까지 9개의 분기를 예측하였다. 표 1에서는 a를 0에서 0.8까지 변화시켜 시뮬레이션한 결과 a를 증가시키면 평균 에러율이 감소하는 것을 알 수 있다. a=0.6부터 평균 에러율의 감소가 발생하지 않았으므로 0.6을 a의 최적값으로 설정하였다. 그림 6과 7에서는 각각 a=0일 때와 a=0.6일 때 시뮬레이션한 결과를 그래프로 나타내었다.

전형적인 GMDH 알고리즘의 경우인 a=0일 때는 평균 에러율이 0.9862였으며 a=0.6일 때는 평균 에러율이 0.688이었다. 따라서 본 논문에서 제안한 데이터 가중율을 적용

한 GMDH 알고리즘에 의해 더 정확한 예측 결과를 얻을 수 있다는 것을 알 수 있었으며, 본 시뮬레이션의 경우에는 30.2%의 예측 성능 개선의 결과를 얻을 수 있었다.


단기 예측의 경우에 대해서도 제안한 GMDH 알고리즘의 예측 정확도를 입증하기 위해서 1996년 4/4분기부터 1998년 4/4분기까지 9개의 분기를 입력 데이터 기간으로 하여 1999년 1/4분기에서 2001년 1/4 분기까지 9개의 분기를 예측하였다. 표 2는 각각 a를 0에서 0.8까지 증가시켜 시뮬레이션한 결과이다.

시뮬레이션 결과 a=0.4일 때부터 가장 작은 평균 에러율을 보였다. 그림 8과 9에서는 각각 a=0일 때와 a=0.4일 때 시뮬레이션한 결과를 그래프로 나타내었다. 전형적인 GMDH 알고리즘의 경우인 a=0일 때는 평균 에러율이 1.4895였으며 a=0.4일 때는 평균 에러율이 0.8995이었다. 따라서 단기 예측의 경우에도 본 논문에서 제안한 데이터 가중율을 적용한 GMDH 알고리즘에 의해 더 정확한 예측 결과를 얻을 수 있다는 것을 알 수 있었으며, 본 시뮬레이션의 경우에는 39.6%의 예측 성능 개선의 결과를 얻을 수 있었다.

표 1. a=0~0.8일 때의 평균 에러율(장기 예측).

Table 1. Average error rate when a=0~0.8(long term prediction).


a	average error
0	0.9862
0.1	0.9854
0.2	0.9763
0.3	0.8564
0.4	0.8234
0.5	0.7644
0.6	<u>0.688</u>
0.7	<u>0.688</u>
0.8	<u>0.688</u>



평균 에러율 = 0.9862 ( — : 기준값. - - - : 예측값 )

그림 6. a=0일 때 전력 수요 예측(장기 예측).

Fig. 6. Power demand forecasting when a=0(long term prediction).



평균 에러율 = 0.688 ( — : 기준값. - - - : 예측값 )


그림 7. a=0.6일 때 전력 수요 예측(장기 예측).

Fig. 7. Power demand forecasting when a=0.6(long term prediction).

표 2. a=0~0.8일 때의 평균 에러율(단기 예측).

Table 2. Average error rate when a=0~0.8(short term prediction).


a	average error
0	1.4895
0.1	1.1599
0.2	1.1932
0.3	1.0383
0.4	<u>0.8995</u>
0.5	<u>0.8995</u>
0.6	<u>0.8995</u>
0.7	<u>0.8995</u>
0.8	<u>0.8995</u>



평균 에러율 = 1.4895 (——: 기준값. ----: 예측값)

그림 8. a=0일 때 전력 수요 예측(단기 예측).

Fig. 8. Power demand forecasting when a = 0(short term prediction).



평균 에러율 = 0.8995 (——: 기준값. ----: 예측값)

그림 9. a=0.6일 때 전력 수요 예측(단기 예측).

Fig. 9. Power demand forecasting when a = 0.6(short term prediction).

IV. 결론

본 논문에서는 GMDH 알고리즘을 이용한 시계열 함수 예측 분야에서는 처음으로 최근의 데이터일수록 예측에 많은 기여를 하도록 하는 알고리즘을 적용하였다. 전형적인 GMDH 알고리즘을 이용한 예측 방법에서는 과거와 최근의 데이터를 동일한 비율로 적용하여 훈련을 하였으나, 예측에 있어 최근의 데이터 일수록 현재 또는 미래의 예측에 있어 더 많은 영향을 미치게 된다는 점을 감안하여 최근의 데이터일수록 훈련에 기여하는 비율을 높이도록 하였다.

전형적인 GMDH 알고리즘의 성능 기준에 데이터 가중 상수를 적용하여 과거의 데이터일수록 성능 기준에 대한 기여도를 줄이고, 최근의 데이터일수록 성능 기준에 대한 기여도를 증가시킴으로써 보다 정확한 예측이 가능하도록 하였다.

본 논문의 시뮬레이션 결과에 따르면, 전력 수요 예측의 결과에서 전형적인 GMDH 알고리즘을 이용한 예측 결과의 평균 에러율은 0.9862%이고, 데이터 가중 알고리즘을 적용한 예측 결과의 평균 에러율은 0.688%였다. 즉, 데이터 가중 알고리즘을 적용한 결과가 적용하지 않은 결과에 비해 30.2% 만큼 더 적은 에러율을 보였다. 따라서 본 논문에서 제안된 데이터 가중 알고리즘을 적용하여 여러 분야의 GMDH 예측에 적용한다면 보다 정확한 예측이 가능할 것으로 기대된다. 하지만 보다 정확한 예측에 큰 영향을 미치는 최적의 데이터 가중율을 찾기 위한 방법은 보다 많은 연구가 요구된다.

참고문헌

- [1] W. Liu, X. Huang, G. Wang, and T. Chai, "The modeling and application of cost prediction based on neural network," *5th Asian Control Conference*, pp. 1308-1312, 2004.
- [2] I. G. Damousis, M. C. Alexiadis, J. B. Theocharis, and P. S. Dokopoulos, "A fuzzy model for wind speed prediction and power generation in wind parks using spatial correlation," *IEEE Trans. Energy Conversion*, vol. 19, no. 2, pp. 352-361, June 2004.
- [3] N. Y. Nikolaev and H. Iba, "Polynomial harmonic GMDH learning networks for time series modeling," *Neural Networks*, vol. 16, pp. 1527-1540, 2003.
- [4] 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.
- [5] 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.
- [6] Y. Nishikawa, J. Nomura, K. Sawada, and T. Kurio, "A method for predicting sales amount by use of IWSM and GMDH," *System and Control*, vol. 27, no. 7, pp. 475-479, 1983.
- [7] 안기범, "GMDH를 이용한 모델링에 관한 연구," 동아대학교 대학원, 석사 학위 논문, 1995년.
- [8] 이창복, "GMDH 알고리즘을 응용한 전처리 선별과 인공신경망을 이용한 한국종합주가지수 예측에 관한 연구," 연세대학교 대학원, 석사 학위 논문, 1999년.
- [9] J.-H. Kim, Y.-C. Hong, and K.-K. Choi, "Direct model reference adaptive pole placement control with exponential weighting properties," *IEEE Trans. Automat. Contr.*, vol. AC-36, no. 9, pp. 1073-1077, Sept. 1991.
- [10] 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.


- [11] S. J. Farlow, *Self-Organizing Methods in Modeling*, Marcel Dekker, New York, 1984.

- [12] 이동철, “Group Method of Data Handling을 이용한 전력 수요 예측 알고리즘에 관한 연구,” 인천대학교 대학원, 석사학위 논문, 2001.



**신재호**

2001년 호서대학교 전자공학과 졸업.  
2005년~현재 인천대학교 전자공학과  
석사과정. 관심분야는 GMDH 알고리즘,  
RFID.



**홍연찬**

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. 관심분야는 GMDH 알고리즘, 신경망  
제어, RFID, 플랜트 제어.