

인공신경망을 이용한 시비된 분뇨로부터의 암모니아 방출량 예측

문영실 · 임영일[†] · 김태완*

환경대학교 화학공학과 FACS 연구실
*환경대학교 식물생명환경과학부
456-749 경기도 안성시 석정동 67
(2006년 7월 3일 접수, 2006년 12월 8일 채택)

Prediction of Ammonia Emission Rate from Field-applied Animal Manure using the Artificial Neural Network

Young-Sil Moon, Youngil Lim[†] and Tae-Wan Kim*

FACS Lab., Dept. Chemical Engineering,

*Faculty of Plant Life and Environmental Sciences, 67 Seokjung-dong, Anseong, Gyeonggi 456-749, Korea

(Received 3 July 2006; accepted 8 December 2006)

요 약

화학비료의 과다사용으로 환경오염의 문제가 심각해 지면서 친환경 농자재(목초재 또는 축산분뇨 등)를 사용하는 유기농업의 필요성이 대두되어 왔다. 이러한 친환경 농자재의 사용량은 작물 종류별, 토양 종류별, 계절별, 재배환경 등에 따라 결정되어야 한다. 유기비료로서 축산분뇨량의 효율적 사용과 축산분뇨로부터의 암모니아 방출량 저감을 위해서는 먼저 축산분뇨의 경작지 시비 후 암모니아 방출모델이 제시되어야 한다. 그리고 암모니아 방출에 영향을 큰 인자들을 찾아내어 이 인자들을 변화시킴으로써 암모니아 방출량을 감소시킬 수 있을 것이다. 이 연구에서는 인공신경망(artificial neural network) 기법을 이용하여 시비된 돈분의 암모니아 휘산량을 예측한다. 유럽지역에서 얻은 암모니아 방출 실험데이터(ALFAM database)를 바탕으로, 암모니아 손실 영향인자에 따른 암모니아 방출량을 Michaelis-Menten 모델식을 이용하여 예측한다. 이 모델식의 모델인자(암모니아 최대 방출량과 암모니아 최대 방출량의 50%에 도달하는 시간)는 feedforward-backpropagation 인공신경망 기법으로 예측하였고, 가중치 분할법(weight partitioning method)으로 암모니아 손실에 미치는 총 15개의 영향인자의 상대적 중요도를 분석하였다. 그 결과 암모니아 방출량은 기후에 따라 크게 좌우되고, 돈분의 상태도 상당한 영향을 주고 있다.

Abstract – As the environmental pollution caused by excessive uses of chemical fertilizers and pesticides is aggravated, organic farming using pasture and livestock manure is gaining an increased necessity. The application rate of the organic farming materials to the field is determined as a function of crops and soil types, weather and cultivation surroundings. When livestock manure is used for organic farming materials, the volatilization of ammonia from field-spread animal manure is a major source of atmospheric pollution and leads to a significant reduction in the fertilizer value of the manure. Therefore, an ammonia emission model should be presented to reduce the ammonia emission and to know appropriate application rate of manure. In this study, the ammonia emission rate from field-applied pig manure is predicted using an artificial neural network (ANN) method, where the Michaelis-Menten equation is employed for the ammonia emission rate model. Two model parameters (total loss of ammonia emission rate and time to reach the half of the total emission rate) of the model are predicted using a feedforward-backpropagation ANN on the basis of the ALFAM (Ammonia Loss from Field-applied Animal Manure) database in Europe. The relative importance among 15 input variables influencing ammonia loss is identified using the weight partitioning method. As a result, the ammonia emission is influenced much by the weather and the manure state.

Key words: Livestock Manure, Ammonia Emission Rate, Artificial Neural Network, Michaelis-menten Equation, Weight Partitioning Method

[†]To whom correspondence should be addressed.
E-mail: limyi@hknu.ac.kr

1. 서 론

현대 농업기술에서 대형 농기계의 사용 및 화학비료 과다 사용은 농경지의 생산성유지 저해요인은 물론 생태계 파괴원인으로 지목되어 왔다. 특히 토양침식, 염류집적 그리고 지하수 오염이 심각한 수준으로 인식되면서 친환경 농자재를 사용하는 유기농업의 필요성이 대두되어 왔다.

목초액, 돈분, 우분, 계분 등을 포함하는 공시퇴비 또는 친환경 농자재의 사용량은 작물 종류별, 토양 종류별, 계절별, 재배환경 등에 따라 적절히 결정되어야 한다. 그동안 사용량을 결정하기 위한 여러 실험과 이를 바탕으로 한 모델이 개발되었다. 개발된 모델은 1년간 또는 재배 기간 동안 퇴비사용량을 결정하는 식으로 사용된다. 하지만, 토양속에 축적된 퇴비 및 양분을 고려하고, 매년 기후 변화에 합당하는 모델은 아직 초보적인 단계라고 여겨지며, 암모니아 방출량을 고려한 퇴비사용량 예측모델은 많은 연구가 진행되어야 한다.

축산분뇨로부터 암모니아 가스의 대기 방출로 인한 환경오염영향은 더욱더 심각해 지고 있다(Ni, 1999). 아시아 지역에서 대기중으로 인위적 암모니아 방출량의 약 77%는 가축분뇨의 시비로 이루어지고 있다고 예측된다(Zhao and Wang, 1994). 1994년도 ECETOC (european center for ecotoxicology and toxicology of chemicals) 보고서에 의하면, 유럽지역에서 인위적 암모니아 발생량 중 약 75%가 축산분뇨에 의한 것이라고 예측하였다(Plochl, 2001). 영국에서는 매년 약 70 kton/year(암모니아기준의 질소 방출량)의 암모니아 가 경작지에 시비되는 축산분뇨로부터 방출되고 있다고 추산한다(Misselbrook et al., 2000).

산성비의 원인이며, 시비된 분뇨내 질소성분의 손실로 지목되는 암모니아 방출량을 감소시키기 위한 여러 방법들이 제시되었지만, 아직도 명확하고 효과적인 기술은 알려져 있지 않고 있다. 왜냐하면, 암모니아 방출은 여러 내생적인 요소들(분뇨내 건조성분양, pH, 암모늄 농도 등)과 외생적 요인들(토양상태, 시비상태, 기후 등)에 의해 복잡하게 연관되어 있기 때문이다.

유기비료로서 축산분뇨량의 효율적 사용과 암모니아 방출량 저감을 위해서는 먼저 축산분뇨의 경작지 시비후 암모니아 방출모델이 제시되어야 한다. 그리고 암모니아 방출에 영향이 큰 인자들을 찾아내어 이 인자들을 변화시킴으로서 암모니아 방출량을 감소시킬 수 있을 것이다.

축산분뇨로부터 암모니아 방출량 예측에 관한 연구는 3년간 9개 유럽국가로부터 13개 연구소들이 참여한 ALFAM(ammonia loss from field-applied animal manure, <http://www.alfam.dk>, 1998-2001) project 에서 찾을 수 있다. 약 6,000여 개의 암모니아 손실 데이터가 수집되었고, 이 데이터로부터 20여 개 이상의 영향인자에 따른 암모니아 방출량이 Michaelis-Menten type 모델식으로 선형 예측되었다(Sommer et al., 2001). 이 연구에 대한 결과는 Sogaad et al.(2002) 에서 요약되어 보고되었다.

또다른 선형모델은 3년간 영국의 6개 지역 농경지에서 얻은 약 500여 개의 데이터를 바탕으로 16개 영향인자에 대한 암모니아 방출량 예측연구(Misselbrook et al., 2005)에서 찾아볼 수 있다. 이 연구에서도 Michaelis-Menten type 모델식의 두 모델인자를 체계적인 방법으로 선형적으로 예측한다.

체계적 비선형모델로서 인공신경망 기법은 암모니아 방출량에 영

향을 주는 인자들 사이의 비선형성을 고려할 수 있고, 생물학적 분뇨 분해과정을 효과적으로 모델링할 수 있는 방안으로 여겨진다(Plochl, 2001). 인공신경망 기법은 미생물의 성장속도를 예측(Hajmeer et al., 1997), 농생태학에서의 응용(Schultz and Wieland, 1997), 화학반응 및 반응기 모델링(Molga, 2003) 등에서 널리 사용되어 왔다.

앞서 기술한 축산분뇨로부터 암모니아 방출량의 예측을 위한 3가지 연구(Sommer et al., 2001; Misselbrook et al., 2005; Plochl, 2001)는 각각 다음과 같은 특징을 갖는다. Sommer et al.(2001)의 연구는 암모니아 손실량을 감소시킬수 있는 분뇨 시비법(application method)을 찾는데 중점을 두고 있다. 따라서 실제 고려되는 입력변수에서는 기후조건과 토양상태에 관하여 충분히 반영되지 않고 있다. Plochl(2001)은 암모니아 손실량이 기상조건에 따라 어떻게 영향을 받는지에 초점을 두었고, 기상상태에 대한 많은 입력변수를 이용하였다. 하지만, 시비방법과 토양상태에 관한 입력변수가 충분하지 않다. Misselbrook et al.(2005)는 가장 최근에 발표된 논문으로 시비방법에 대한 변수는 고려되지 않았지만, 토양, 기후, 분뇨 그리고 경작지 상태에 대한 폭넓은 영향인자를 고려한다.

본 논문에서는 시비된 돈분으로부터 암모니아의 휘산에 영향을 줄 수 있는 15가지 영향인자를 고려하는 인공신경망 모델을 구축하여 암모니아 휘산량을 예측할 것이다. 인공신경망의 학습은 유럽의 ALFAM database(ALFAM, 2001)에서 유효한 42개 데이터 집합을 바탕으로 수행하였다.

본 논문의 2장에서는 축산분뇨 시비사용량 예측모델을 소개하고, 3장에서는 축산분뇨로부터 암모니아 휘산량 예측모델에 관하여 다루며, 여기에서 암모니아 휘산에 미치는 15가지 영향인자를 설명한다. 본 연구에서 사용된 인공신경망(artificial neural network) 기법과, 가중치 분할법(weight partitioning method)을 이용한 모델의 영향인자에 대한 중요도 분석 기법은 부록 A1에서 간단하게 소개하며, 4장에서는 경작지에 시비된 돈분에서 암모니아 휘산량을 추정하는 Michaelis-Menten 식의 두 모델인자를 인공신경망 기법으로 예측한다. 마지막 장에서 본 연구에 대한 결론을 내릴 것이다.

2. 축산분뇨 시비사용량 예측모델 (manure application rate model in the field)

친환경 농자재중의 하나로서 축산분뇨(livestock manure) 내 여러 유용한 비료성분중 질소는 가장 많이 사용되는 시비량 기준성분이다. 이 연구에서는 질소성분을 기준한 연간 시비량(application rate per year, $\dot{N}_{field} \left[\frac{\text{kg-N}}{\text{year} \cdot \text{ha}} \right]$), 또는 시비량(application rate: $N_{field} \left[\frac{\text{kg-N}}{\text{ha}} \right]$)을 사용하여 농경지내 물질수지식을 세운다(Moon et al., 2006).

Fig. 1에서는 농경지 내 유입되는 질소성분유량(nitrogen mass flux)과 유출되는 질소성분유량을 도식화하고 있다. 흐르는 농경수의 유출입(\dot{N}_{inf} , $\dot{N}_{effluent}$)과 지하수로의 침투($\dot{N}_{penetration}$)는 액상으로서 유입되거나 유실되고, 고액상의 현탁액인 슬러리 상태 축산분뇨(livestock manure slurry: \dot{N}_{lms})가 투입된다. 투입된 축산분뇨의 주된 질소성분 손실(\dot{N}_{NH3})은 대기 중으로의 휘산에 기인한다(Sommer and Hutching, 2001).

농경지내 질소성분유량 수치에 미치는 또 다른 요소는 작물의 성장에 필요한 질소량이다. 이 필요량(\dot{N}_{crops})은 작물의 종류에 따라 주로 결정된다. 본 연구에서 작물에 필요한 질소량은 작물 흡수량




Fig. 1. Nitrogen balance in the field (Moon et al. 2006).

을 기준으로 한다.

Fig. 1에서 보여주는 모형을 바탕으로 시간에 따라 변화하는 질소성분 질량보존식(비정상상태 모델)과 시간에 따라 일정한 질소성분 질량보존식(정상상태 모델)을 제시한다.

2-1. 비정상상태 모델(unsteady-state model)

질소성분의 농경지내 축적속도($\dot{N}_{accumulation}$)는 유입되는 모든 유입속도와 유출되는 모든 유출속도의 차로써 표현하는 질소성분에 대한 비정상상태 물질수지식(unsteady-state material balance)은 다음과 같다.

$$\frac{dN_{field}}{dt} \equiv \dot{N}_{accumulation} = \sum_{i=1}^P (\dot{N}_i)_{inlet} - \sum_{j=1}^Q (\dot{N}_j)_{outlet} \quad (1)$$

여기에서 P와 Q는 각각 유입흐름의 수와 유출흐름의 수를 말한다. Fig. 1을 바탕으로 식 (1)은 다음과 같이 표현된다.

$$\begin{aligned} \frac{dN_{field}}{dt} \equiv \dot{N}_{accumulation} \\ = \dot{N}_{inf} + \dot{N}_{lms} - (\dot{N}_{effluent} + \dot{N}_{NH3} + \dot{N}_{crops} + \dot{N}_{penetration}) \end{aligned} \quad (2)$$

- 식 (2)은 다음과 같은 가정하에서 더욱 간결해질 수 있다.
- 가정 1. 흐르는 농경수의 유출입이 없거나 농경지내 질소량의 유출입량이 비슷하다면, $\dot{N}_{inf} \approx \dot{N}_{effluent}$
 - 가정 2. 지하수로의 질소성분 유실이 매우 적어서 무시할 수 있다면, $\dot{N}_{penetration} \approx 0$. 따라서 식 (2)는 다음과 같이 정리된다.

$$\frac{dN_{field}}{dt} \equiv \dot{N}_{accumulation} = \dot{N}_{lms} - (\dot{N}_{NH3} + \dot{N}_{crops}) \quad (3)$$

윗식은 간결화된 비정상상태 물질수지식으로 토양에 축적되어있는 영양상태에 따라 매년 시비량을 조절한다고 할 때 사용될 수 있는 동적모델(dynamic model)이다.

2-2. 정상상태 모델(steady-state model)

시간에 따른 질소변화량($\dot{N}_{accumulation}$)이 매우 적을 때, 즉 총 유입되는 양과 총 유출되는 양이 같아서 축적되는 양이 없다면, 정상상태로 간주되며 식 (3)은 다음과 같이 정리된다.

$$\frac{dN_{field}}{dt} \equiv \dot{N}_{accumulation} \cong \dot{N}_{lms} - (\dot{N}_{NH3} + \dot{N}_{crops}) \quad (4)$$

따라서 축산분뇨의 연간 시비량(\dot{N}_{lms})은 다음과 같이 정의할 수 있다.

$$\dot{N}_{lms} = \dot{N}_{NH3} + \dot{N}_{crops} \quad (5)$$

즉, 시비량은 대기중으로 손실되는 암모니아양과 작물의 성장에 필요한 양으로 결정된다. 어느 일정기간 동안 투입되어야 할 총 시비량(application rate: N_{lms} [kg/ha])을 구하기 위하여 식 (5)를 시간에 대하여 적분한다.

$$N_{lms} \equiv \int_0^{N_{lms}} dN_{lms} = \int_0^t \dot{N}_{NH3} dt + \int_0^t \dot{N}_{crops} dt \quad (6)$$

주어진 기간 동안 총 암모니아 손실량은 $N_{NH3} = \int_0^t \dot{N}_{NH3} dt$, 작물이 필요한 총량은 $N_{crops} = \int_0^t \dot{N}_{crops}$ 라고 하면, 식 (6)은 다음과 같이 재정리된다.

$$N_{lms} = N_{NH3} + N_{crops} \quad (7)$$

작물 성장에 필요한 질소량은 작물 흡수량으로 간주하고, 그 양은 Park et al.(2004)에서 찾아볼 수 있으며, 본 연구에서는 대기 중으로 손실되는 암모니아양(N_{NH3})의 예측에 중점을 두고, 이에 대하여 다음 장에서 설명한다.

3. 축산분뇨의 암모니아 손실량 예측모델

Michaelis-Menten type 식은 시간에 따른 암모니아 총 손실량(N_{NH3})을 예측하기 위하여 많은 연구자들이 사용해 왔다(Sommer and Ersboll, 1994; Sommer et al., 2001; Ploch, 2001; Misselbrook et al., 2005). 이식은 다음과 같이 표현된다.

$$N_{NH3}(t) = N_{max} \frac{t}{t + K_m} \quad (8)$$

여기에서 N_{NH3} 는 [kg/ha] 단위를 갖는 어떤 시간 t에서 누적 질소 손실량을 의미하며, N_{max} [kg/ha]와 K_m [hr]은 모델인자들로써 실험 결과를 이용하는 경험적 실험식(empirical equation)으로 추정될 수 있다. N_{max} [kg/ha]는 분뇨에서 방출될 수 있는 최대 암모니아 양을 의미한다. N_{max} [hr]은 최대 암모니아 방출량의 반($\frac{N_{max}}{2}$)에 도달하는 시간을 의미하며, 초기 암모니아 손실속도, $v_{initial}$ 는 K_m 에 반비례하고 다음과 같이 정의한다.

$$v_{initial} \equiv N_{NH3}(0) = N_{max}/K_m \quad (9)$$

암모니아 손실속도(ammonia loss rate: \dot{N}_{NH3})는 식 (8)을 시간에 대하여 미분하여 구할 수 있다(Sommer et al., 2001).

$$\dot{N}_{NH3}(t) \equiv \frac{dN_{NH3}}{dt} = N_{max} \frac{K_m}{(t + K_m)^2} \quad (10)$$

식 (8)과 식 (10) 모두는 시간에 따른 암모니아 손실량을 측정한 실험데이터를 이용하여 모델인자값들을 추정할 때 사용된다. 식 (10)은 실험값으로부터 모델인자값을 예측하기 위하여 주어진 시간 범

위 (t+Dt)에서 다음과 같이 표현될 수 있다(Sommer et al., 2001; Sommer and Hutching, 2001; Misselbrook et al., 2005).

$$\dot{N}_{NH_3}(t, \Delta t) = N_{max} \frac{K_m}{(t+K_m)(t+\Delta t+K_m)} \quad (11)$$

식 (11)는 시간에 따른 암모니아 휘산량 실험값으로부터 모델인자를 구하기 위해 본 연구에서 실제로 사용되는 식이다.

Michaelis-Menten 형태의 식에서 두 모델인자(N_{max} , K_m)는 토양 상태(soil condition), 날씨(climate), 축산분뇨의 상태(livestock manure condition), 그리고 경작지 조건(field condition) 등에 따라 변할 수 있다. 다음은 이 두 모델인자값에 영향을 주는 독립변수들에 대하여 알아본다.

3-1. 암모니아손실에 영향을 주는 독립변수들

암모니아 손실에 영향을 주는 인자들은 분뇨의 분해반응 속도를 조절할 수 있는 변수들이다. 이러한 영향인자는 크게 토양조건(soil) 기후조건(weather), 분뇨상태(manure), 시비방법(application) 그리고 경작지조건(land state) 등으로 구분되며, 총 40여 개의 인자들로 구분되어 있다. 이러한 구분은 ALFAM 최종보고서(Sommer et al., 2001)에 잘 설명되어 있고, 실험데이터는 ALFAM database(<http://www.alfam.dk>, Denmark)에서 선택적으로 받아볼 수 있다.

축산분뇨의 암모니아 손실에 영향을 주는 많은 독립변수 중에서 인공신경망 입력변수로 사용할 독립변수를 선별하는 것은 매우 힘든 과정중의 하나이다. 확보한 ALFAM database의 시간에 따른 분의 암모니아 휘산량에 관한 2,300여 개 실험데이터(또는 300여 개의 독립된 실험수)를 바탕으로 Michaelis-Menten 모델식의 2개 모델인자값을 구할 수 있는 유효한 데이터를 선별하였다.

암모니아 손실량에 영향을 주는 입력변수는 30개 이상이지만, 실험적으로 측정된 값이 존재하면서, 공통적으로 측정된 입력변수는 많지 않다. 입력변수수가 많으면, 유효한 데이터의 수는 매우 적었다. 17개의 입력변수로 이루어진 데이터 집합의 수는 19개이고, 15개 입력변수로 이루어진 데이터 집합의 수는 42개이며, 11개 입력변수에 대해서는 95개의 데이터 집합이 존재한다.

본 연구에서는 15개 영향인자들(Table 1참조)에 대한 측정값이 존

재하는 42개의 유효 실험데이터 집합을 사용한다. 이들 42개 유효 데이터의 평균 최대 암모니아 손실량 $N_{max} = 37.2 \text{ kg/ha}$ 이고, 최대 암모니아 손실량의 반에 도달하는 평균시간 $K_m = 18.4 \text{ hr}$ 이다. 따라서 초기손실속도 $v_{initial} = N_{max}/K_m = 2.02 \text{ kg/ha}\cdot\text{hr}$ 이다. 두 모델인자값의 표준편차는 비교적 높은 편으로 이는 실험데이터수가 적고, 상이한 조건과 상이한 지역에서 유럽내 여러 연구자들이 측정된 데이터이기 때문으로 풀이된다.

다음은 시간에 따른 암모니아 휘산량에 관한 42개 실험데이터 집합을 이용하여 어떻게 Michaelis-Menten 모델인자값을 정하는지에 관하여 소개한다.

3-2. 실험값으로부터 Michaelis-Menten 모델 인자값 결정

ALFAM database에서 주어진 값은 입력변수(혹은 실험변수)는 일정하게 유지하면서 시간에 따른 암모니아 손실속도(kg-N/ha·hr)가 측정되었다. 이 데이터를 이용하여 Michaelis-Menten 식 (11)의 두 모델인자값이 추정된다. Fig. 2는 시간에 따른 암모니아 손실속도에




Fig. 2. Michaelis-Menten model parameter estimation from the experimental data for ammonia emission rate with respect to time (squares: experimental data, solid line: model estimation).

Table 1. 15 input variables influencing ammonia volatilization from field-applied pig manure

No.	Variables	Index	Range	Units or Comments
1	soil type	p ₁	[1, 4]	
2	pH	p ₂	[4.9, 9.2]	1 = sandy, 2 = clay, 3 = loam, 4 = organic
3	weather Max. Temperature: 1 st -day	p ₃	[0, 20]	°C
4	Min. Temperature: 1 st -day	p ₄	[0, 20]	°C
5	Max. Temperature: 2 nd -day	p ₅	[0, 20]	°C
6	Min. Temperature: 2 nd -day	p ₆	[0, 20]	°C
7	Radiation sum within first two days	p ₇	[500, 20000]	W/m ²
8	Wind speed	p ₈	[0, 5]	m/s
9	Manure Dry matter	p ₉	[1.0, 13.0]	%
10	TOTAL nitrogen	p ₁₀	[1.0, 8.5]	(g-nitrogen)/(kg-manure)
11	TAN*	p ₁₁	[0.4, 6.0]	(g-nitrogen)/(kg-manure)
12	pH	p ₁₂	[5, 9.2]	
13	Agronomic factors Manure application method	p ₁₃	[0, 4]	0 = broad spread, 1 = band spread, 2 = trailing shoe, 3 = Open-slot injection, 4 = closed slot injection
14	Application rate	p ₁₄	[20, 80]	(ton-slurry)/(ha-field)
15	Land type	p ₁₅	[1, 4]	1 = Grass, 2 = Stubble, 3 = bare soil, 4 = Growing crops
N _{max} (kg/ha)			37.2 (standard deviation = 28.8)	K _m (hr)
				18.4 (standard deviation = 22.8)

*TAN: total ammoniacal nitrogen

대한 12개 실험값으로부터 두 모델인자값(K_m , N_{max})을 추정하는 그 래프를 보여준다.

Michaelis-Menten 모델인자값의 추정에서는 Matlab 함수, `fminsearch` 를 이용하여 실험값과 모델값의 차의 제곱의 합을 최소화하는 모델 인자값을 찾는다.

$$\min_{N_{max}, K_m} MSE = \sum_{i=1}^n (x_{i,exp} - x_{i,model})^2$$

$$s.t. x_{i,model} = \frac{N_{max} \cdot K_m}{(t_i + K_m)(t_i + \Delta t_i + K_m)} \quad (12)$$

이 방법을 이용하여 구한 모델인자값은 입력변수가 15개인 경우 총 42개이며, 약 400여 개의 시간에 따른 암모니아 손실속도값이 이 용되었다. 그 결과값은 부록 Table A4에서 입력변수와 함께 보여준 다. 여기에서 구한 42개 K_m , N_{max} 는 앞으로 측정값 또는 실제값 등 으로 불리며, 이 두 값은 인공신경망 기법으로 예측하기 위한 훈련 집합으로 사용된다.

4. 암모니아 방출량 예측을 위한 Michaelis-Menten 식의 모델인자값 추정

본 장에서는 feedforward backpropagation neural network을 이용 하여 경작지에 시비된 축산분뇨의 암모니아 방출량을 예측하는 Michaelis-Menten 식의 모델인자값을 추정한다. 이 수치해석은 공 학용 계산프로그램 중의 하나인 Matlab(Mathworks, USA, 2005)의 neural network toolbox를 사용하여 계산하였다. 부록 A1에서는 principle component analysis(PCA)와 함께 사용된 인공신경망 (artificial neural network) 기법과, 가중치 분할법(weight partitioning method)을 이용한 모델의 영향인자에 대한 중요도 분석 기법이 소 개되었다.

암모니아 총손실량은 ALFAM database 로부터 15개 입력변수에 대한 유효한 42개 돈분 데이터를 바탕으로 인공신경망 기법을 이용 하여 예측된다. Fig. 3은 PCA 로 전처리된 ANN에서 은닉층(hidden layer)의 뉴런수 10부터 30개에 따른 상관계수(R^2)와 오차(MSE)를 보여준다. 반복계산수(training epochs)는 500번으로 제한하였고, 목 표오차는 1.0×10^{-4} 으로 설정하여 계산을 수행하였다. 뉴런수에 따라 불규칙한 성능을 보여주는 이유는 충분한 반복계산수를 사용하지 않고 500회에 한정하였으므로 오차가 수렴하지 않았기 때문으로 생 각된다. Fig. 3에서 은닉층의 뉴런수가 24일 때 가장 좋은 성능을 보여주며, Michaelis-Menten 모델식의 2개 모델인자를 예측하는 최 적 인공신경망 구조는 15-24-2으로 볼 수 있다.

ANN 15-24-2에서 Fig 4는 611회 반복 계산 후 training performance (or MSE)가 목표 설정치에 도달함을 보여준다. 여기에서 성능값은 부록 A1의 식 (A1)에서 정의하는 MSE(mean square error)를 의미 한다. 상관계수(R^2)와 MSE는 Table 2에서 선형 모델(linear regression model; Sommer et al., 2001; Sogaad et al., 2002)과 인공신경망 결과와 비교되고 있다. 축산분뇨로부터 암모니아방출은 영향 인자 간 복잡하고 비선형적인 관계속에서 결정되므로(Sommer et al., 2003), 선형모델에 비교하여 인공신경망 기법이 높은 예측성능을 나타낸다.

Fig 5에서는 42개 측정값(또는 실험값)에 대하여 선형모델에 의 한 예측값과 ANN 15-24-2 예측값의 상관성을 비교하고 있다. ANN




Fig. 3. The effect of the neuron number of hidden layer on the correlation coefficient (R^2) and the MSE of a) K_m , and b) N_{max} , for 500 training epochs of 42 experimental data.




Fig. 4. Training performance of ANN 15-24-2 for 611 training epochs of 42 experimental data.

15-24-2은 거의 완벽하게 실험값을 예측하고 있지만, 이는 사용되어 진 42개 실험값의 예측에만 유효한 것이다.

부록 A1에서 설명하듯이 인공신경망 기법에서는 가중치 분석을 통한 입력변수와 출력변수의 중요도를 쉽게 해석할 수 있다. ANN




Fig. 5. Correlation of model parameters (K_m and N_{max}) between measured by experiments and predicted by linear regression model and ANN 15-24-2.

Table 2. Correlation coefficient (R^2) and mean square error (MSE) in linear regression model and ANN 15-24-2

Model	R^2 for K_m	R^2 for N_{max}	MSE
Linear	0.565	0.800	216.3
ANN 15-24-2	0.999	0.999	3.7×10^{-5}

Table 3. Relative significance of 15 ammonia emission factors obtained from ANN 15-24-2

	Input variables	index	Significance (%)	rank
Soil (12.9%)	Type	p1	7.6	3
	pH	p2	5.3	13
Weather (42.8%)	Max . Air Temp(1 st -day)	p3	5.5	11
	Min . Air Temp(1 st -day)	p4	5.8	9
	Max . Air Temp(2 nd -day)	p5	5.0	15
	Min . Air Temp(2 nd -day)	p6	6.7	6
	Radiation for first two days	p7	7.4	4
	Wind Speed	p8	12.5	1
	Manure (23.7%)	DM	p9	5.9
	Total Nitrogen	p10	5.4	12
	TAN	p11	5.7	10
	pH	p12	6.7	6
Agronomic factors (20.5%)	Application method	p13	8.4	2
	Application Rate (kg/ha)	p14	5.2	14
	Crops Type	p15	7.0	5

15-24-2 구조에서 얻을 수 있는 가중치는 input-hidden layer 사이의 (24×15) 행렬과 hidden-output layer 사이에서의 (24×2) 행렬이고 이 두 행렬을 이용하여 입력변수의 중요도를 분석한다. Table 3은 ANN 15-24-2 구조에서 가중치분할법을 이용하여 입력변수간 상대적 중요도를 분석한 결과이다. 가장 큰 영향은 날씨(43%)이고, 돈분의 상태(24%), 시비방법 및 시비량 등(20%), 그리고 토양상태(13%)가 그 뒤를 잇는다. 즉, 기후에 따라 암모니아 휘산량이 크게

좌우되고, 돈분의 상태도 큰 영향을 주고 있다. 특히 풍속(wind speed), 온도(temperature), 그리고 시비방법(application method)은 암모니아 휘산에 가장 큰 영향을 주는 인자로 파악된다.

5. 결 론

시비된 축산분뇨로부터 암모니아 휘산량을 예측하고 축산분뇨의 적정시비량을 구하기 위하여 정상상태 모델과 비정상상태 모델을 제시하였다. 암모니아 휘산량은 Michaelis-Menten 식을 이용하여 예측하며, 이 모델 인자는 선형모델과 인공신경망 기법으로 구하여 비교하였다. 인공신경망 학습에 필요한 실험데이터는 ALFAM database에서 얻은 약 300여 개 돈분 실험데이터 집합을 바탕으로 유효한 데이터 42개 집합을 이용하였다.

암모니아 휘산에 영향을 주는 인자들은 토양, 기후, 분뇨, 시비방법 그리고 경작지 조건 등으로 구분하여 제시하였으며, 이들 중 15 개의 입력변수를 인공신경망에서 사용된다. 인공신경망 기법 중 feedforward backpropagation neural network이 사용되었고, 이 방법에 대하여 부록에서 기술하였다. 선형모델은 암모니아 방출 영향인자들간의 비선형성을 고려할 수 없기 때문에 낮은 상관계수값을 보이고 있으며, 인공신경망기법은 거의 완벽한 예측성능을 나타내었다. 인공신경망기법에서 구한 가중치의 조합을 통하여 암모니아 방출에 크게 영향을 주는 인자들을 찾아냈다.

본 연구에서는 42개의 유럽지역 실험데이터를 이용하였으므로, 한국적 풍토에 적용하기에는 한계가 있을 것이다. 또한, 일반적으로 100여 개 이상의 실험데이터를 바탕으로 인공신경망을 학습시킨다고 볼 때, 충분하지 못한 실험데이터수로 인하여 그 결과값에 대한 신뢰도가 높지 않다.

충분한 실험데이터가 확보되고, 본 연구에서 제시한 인공신경망 기법을 이용한다면, 여러 영향인자들이 비선형적으로 복잡하게 얽힌 암모니아 휘산량을 비교적 정확하게 예측할 수 있을 것이며, 매년 농가에서 사용해야 할 축산분뇨(퇴비)의 적정사용량을 제시할 수

있을 것이다. 이에 따른 농가 경작비용절감 및 환경오염 감소 등을 기대할 수 있다.

감 사

본 연구는 2004-2006년도 국립한경대학교 GRRC(Gyeong-gi regional research center, Project No. 3-1) 과제로부터 재정적인 지원을 받아 수행되었다. ALFAM database를 제공해준 ALFAM (<http://www.alfam.dk>) 관계자 Mr. Sommer와 Mr. Hutchings에게 감사함을 전한다.

사용기호

K_m	: time to reach the half of maximum ammonia emission [hr]
$\dot{N}_{accumulation}$: accumulation rate of nitrogen into the field [$\frac{kg-N}{hr \cdot ha}$]
\dot{N}_{crops}	: crops uptake flowrate of nitrogen-based ammonia
$\dot{N}_{effluent}$: effluent flowrate of nitrogen-based ammonia [$\frac{kg-N}{hr}$]
\dot{N}_{field}	: application rate per year based on nitrogen [$\frac{kg-N}{year \cdot ha}$]
N_{field}	: application rate based on nitrogen [$\frac{kg-N}{hr}$]
\dot{N}_{inf}	: influent flowrate of nitrogen-based ammonia [$\frac{kg-N}{hr}$]
\dot{N}_{inlet}	: inlet flowrate of nitrogen-based ammonia [$\frac{kg-N}{hr}$]
\dot{N}_{lms}	: nitrogen-based ammonia flowrate of livestock manure slurry: [kg/hr·ha]
N_{max}	: Maximum ammonia emission from field-applied livestock manure [kg/ha]
\dot{N}_{NH3}	: ammonia loss rate [$\frac{kg-N}{hr \cdot ha}$]
N_{NH3}	: total ammonia loss [kg/ha]
\dot{N}_{outlet}	: outlet flowrate of nitrogen-based ammonia [$\frac{kg-N}{hr}$]
$\dot{N}_{penetration}$: penetration flowrate into underground water of nitrogen-based ammonia [$\frac{kg-N}{hr}$]
$v_{initial}$: initial ammonia loss rate [$\frac{kg}{hr \cdot ha}$]

참고문헌

- Kim, D.-S., "Neural Networks: Theory and Applications," Hi-Tech Jeong-Bo, Seoul(1994).
- Park, Y.-H., Lee, Y., No, J.-S., Park, K.-R. and Park, M.-H., "Integrated Nutrient Management (INM)," National Institute of Agricultural Science and Technology(NAIST), Final report(2004).
- ALFAM (Ammonia Loss from Field-applied Animal Manure, <http://www.alfam.dk>), An EU-supported Project to Co-ordinate and Disseminate Information on the Losses of Ammonia from Field-Applied Animal Manures, Final Report(2001).
- ECETOC, Ammonia Emissions to Air in Western Europe, Technical Report, no. 62, European Centre for Ecotoxicology and Toxicology of Chemicals (ECETOC), Brussels, Belgium, 196(1994).
- Garson, Interpreting Neural Network Connection Weights, *AI Expert*, **6**(7), 47-51(1991).
- Goh, A. T. C., "Seismic Liquefaction Potential Assessed by Neural Networks," *J. Geotech. Eng., ASCE* **120**(9), 1467-1480(1994).
- Hajmeer, M. N., Basheer, I. A. and Najjar, Y. M., "Computational Neural Networks for Predictive Microbiology: II. Application to Microbial Growth," *Int. J. Food Microbiology*, **34**, 51-66(1997).
- Misselbrook, T. H., van der Weerden, T. J., Pain, B. F., Jarvis, B. F., Chambers, B. J., Smith, K. A., Phillips, V. R. and Demmers, T. G. M., "Ammonia Emission Factors for UK Agriculture," *Atmos. Environ.*, **34**, 871-880(2000).
- Misselbrook, T. H., Nichol森, F. A. and Chambers, B. J., "Prediction Ammonia Losses Following the Application of Livestock Manure to Land," *Bioresource Technology*, **96**, 159-168(2005).
- Molga, E. J., "Neural Network Approach to Support Modeling of Chemical Reactors: Problems, Resolutions, Criteria of Application," *Chem. Eng. Pro.*, **42**(8-9), 675-695(2003).
- Moon, Y. S., Lim, Y. I. and Kim, T. W., "Process Systems Engineering in Agriculture: Environment-Friendly Agricultural System Development of Rural Resources," Spring meeting of KICChE, April 21, 2006, DaeGoo, Korea(2006).
- Ni, J., "Mechanical Models of Ammonia Release from Liquid Manure: a Review," *J. Agric. Eng. Res.*, **72**(1), 1-17(1999).
- Plochl, M., "Neural Network Approach for Modeling Ammonia Emission After Manure Application on the Field," *Atms. Environ.*, **35**, 5833-5841(2001).
- Schultz, A. and Wieland, R., "The Use of Neural Networks in Agroecological Modeling," *Com. Elec. Agr.*, **18**, 73-90(1997).
- Sogaad, H. T., Sommer, S. G., Hutching, N. J., Huijsmans, J. F. M., Bussink, D. W. and Nicholson, F., "Ammonia Volatilization from Field-applied Animal Slurry-the ALFAM Model," *Atmos. Environ.*, **36**, 3309-3319(2002).
- Sommer, S. G. and Ersboll, A. K., "Soil Tillage Effects on Ammonia Volatilization from Surface-applied or Injected Animal Slurry," *J. Environ. Quality*, **23**, 493-498(1994).
- Sommer, S. G. and Hutching, N. J., "Ammonia Emission from Field Applied Manure and Its Reduction," *Eur. J. Agronomy*, **15**, 1-15(2001).
- Sommer, S. G., Hutchings, N. J. and Carton, O. T., "Ammonia Losses from Field Applied Manure," DIAS Report No. 60, Danish Ins. Agr. Sci. (DIAS), Denmark(2001).
- Sommer, S. G., Genermont, S., Cellier, P., Hutchings, N. J., Olesen, J. E. and Morvan, T., "Processes Controlling Ammonia Emission from Livestock Slurry in the Field," *Europ. J. Agronomy* **19**, 456-486(2003).
- Zhao, D. W. and Wang, A. P., "Estimation of Anthropogenic Ammonia Emission in Asia," *Atmos. Environ.*, **28**(4), 689-694(1994).

Appendix

A1. Artificial neural network using feedforward backpropagation method

기본적인 인공신경망 구조는 한 개의 입력층(input layer), 은닉층(hidden layers), 한 개의 출력층(output layer)의 구조이다. 입력층과 출력층의 뉴런수는 각각 입력변수와 출력변수의 수와 같게 한다. 은닉층 안의 뉴런의 최적수는 광범위한 테스트를 거쳐 결정된다(Plochl, 2001).

Fig. A1은 간단한 인공신경망 구조 r-1-1(input variable number-hidden layer neuron number-output variable number)에서의 구성요소를 보여준다. 입력변수(p), 가중치(w), 편심치(b) 그리고 출력값(a)을 보여준다.

암모니아 방출량 예측모델의 경우, Input layer(입력층)에 들어가는 입력값은 15가지의 정보로서 토양, 기후, 분뇨 그리고 경작지 조건 등이다. Hidden layer(중간층)에서는 입력값, 가중치(weight), 편심치(bias)를 이용하여 계산하고 전환함수(transfer function)를 거쳐 출력층에 값을 전달한다. 여기에서 사용되는 전환함수는 sigmoid function이다. Output layer(출력층)로 출력될 출력값으로는 본문에서 설명하였듯이 Michaelis-Menten 형태의 식에서 두 모델인자(N_{max}, K_m) 값이며, 전환함수는 purelinear function이 사용된다.

인공신경망으로 들어가는 입력값의 표준화와 가능성있는 입력변수간의 상관관계를 감소시키기 위하여 Principle component analysis(PCA)를 인공신경망의 전처리 과정으로 사용된다. 평균 μ = 0, 표준편차 σ = 1로 표준화된 입력변수 집합(행렬크기: 15×42)은 일정값(본 연구에서는 0.0025) 이상의 분산값을 갖는 인자만 principle component로 선택된다. 이 단계에서 입력변수수는 15개에서 12개로 감소하고, 이렇게 변환된 집합(행렬크기: 12×42)은 인공신경망의 입력변수로 사용된다.

인공신경망 구조가 정해지면, 가중치(weight), 편심치(bias) 값은 알려진 입력값과 출력값을 사용하여 구해야 하며, 이러한 과정을 학습(learning)이라고 한다. 또한 은닉층의 뉴런수도 학습을 통하여 오차값을 가장 적게 할 수 있는 최적 개수를 찾아야 한다. 일반적으로 많이 사용되는 오차함수는 mean square error(MSE)이다.

$$E = \frac{1}{N_{data}} \left(\sum_{i=1}^{N_{data}} (a_{exp,i} - a_{m,i})^2 \right) \tag{A1}$$

여기에서 E는 오차값 또는 인공신경망 성능지수(performance index)이고, N_{data}는 데이터 수, a_{exp}는 실험값 혹은 원하는 출력값을 의미하며, a_m은 선택된 인공신경망 구조에서 얻어지는 출력값을 뜻한다.




Fig. A1. Components in ANN (artificial neural network).

A1.1. Feedforward backpropagation neural network

인공신경망(ANN)의 학습 과정을 차례대로 살펴보면 프로그램을 시작할 때 네트워크의 상태를 결정하는 연결강도(weight)와 편심치(offset or bias)를 임의수로 초기화한다.

초기화 시킨 후엔 학습패턴을 설정하여 학습패턴의 값을 입력층에 제시하면 중간층 유닛의 계산이 실행되고 출력층 유닛의 계산이 실행된다. 이 단계까지가 입력층으로부터 중간층을 거쳐 출력층에까지 전방향처리(feed-forward)가 된다. 다음 단계는 오차를 수정하는 과정이다. 학습패턴의 목표값과 실제 출력층에 도달한 값을 비교하여, 출력층 유닛의 오차를 구한다.

중간층 / 출력층간의 연결강도와 중간층의 출력으로부터 중간층 유닛의 오차를 구한다. 여기에서 구해진 중간층 유닛의 오차를 이용하여 중간층과 출력층 사이의 연결강도와 출력층 유닛의 offset을 변경시키고, 출력층 유닛의 오차를 이용해 입력층과 중간층 사이의 연결강도와 중간층 유닛의 offset을 변경하는데 이 단계를 출력층으로부터 중간층과 입력층에의 역방향 처리(backward)라 한다(Kim, 1994). 이러한 방법을 취하는 인공신경망 기법(feedforward backpropagation neural network)을 본 연구에서 사용하였다.

A1.2 가중치분석을 통한 입력변수와 출력변수간 중요도 해석

인공신경망 기법의 장점중의 하나는 입력변수와 출력변수간 비선형적 관계에 대한 민감도(sensitivity) 또는 중요성(importance)을 쉽게 해석할 수 있다는 것이다. 이 해석은 가중치(weight)와 편심치(bias)를 함께 이용하면서 수행될 수 있다(Goh, 1994).

Table A1. Weights in a 3-4-1 ANN

Neuron number in hidden layer(j)	Weights (w _j)			
	p ₁ (input-hidden layer)	p ₂ (input-hidden layer)	p ₃ (input-hidden layer)	q ₁ (hidden-output layer)
1	-1.67624	3.29022	1.32466	4.57857
2	-0.51874	-0.22921	-0.25526	-0.48815
3	-4.01764	2.12486	-0.08168	-5.73901
4	-1.75691	-1.44702	0.58286	-2.65221

Table A2. Weights product (X_{ij}) and its summation (Σ_iX_{ij})

Neuron number in hidden layer(j)	X _{ij}			Σ _i X _{ij}
	p ₁	p ₂	p ₃	
1	7.674782	15.0645	6.065049	28.80433
2	0.253223	0.111889	0.124605	0.489717
3	23.05728	12.19459	0.468762	35.72063
4	4.659694	3.837801	1.545867	10.04336

Table A3. Fraction of weights product to its summation (Y_{ij}), summation of its fraction for each input variable (S_j) and relative importance of input variables (Z_j)

Neuron number in hidden layer(j)	Y _{ij}			S _j
	p ₁	p ₂	p ₃	
1	0.266445	0.522994	0.21056	1
2	0.51708	0.228477	0.254443	1
3	0.645489	0.341388	0.013123	1
4	0.463958	0.382123	0.153919	1
S _j	1.892972	1.474982	0.632046	4
Z _j	0.473	0.369	0.158	1

입력변수와 출력변수간의 상대적 중요성을 가중치만을 이용하여 평가할 수 있는 간단한 방법은 은닉층과 출력층사이의 연결가중치를 각각의 입력변수에 대하여 분할하는 것이다(Garson, 1991). 이 방법은 다음과 같은 예제를 통하여 설명할 수 있다.

3-4-1 구조의 backpropagation-feedforward neural network에 관한 어느 가중치값이 Table A1과 같다고 한다.

i) 먼저 입력-은닉층 사이의 가중치와 은닉-출력층 사이의 가중치 값을 곱하여 절댓값을 취한다. 이 값을 X_{ij} 라고 하면,

$$X_{ij} = \text{abs}(w_{p,i,j} \cdot w_{q,j}), 0 \leq i \leq 3, 0 \leq q \leq 4 \quad (A2)$$

여기에서 w_p 는 입력-은닉층 사이의 가중치, w_q 는 은닉-출력층 사

Table A4. Michaelis-Menten equation parameters derived from experimental data measured at 15 input variables for field-applied pig manure (Sommer et al., ALFAM., 2001)

No.	K_m	N_{max}	p1	p2	p3	p4	p5	p6	p7	p8	p9	p10	p11	p12	p13	p14	p15
1	14.22	21.28	1	6.60	11.90	11.50	14.50	10.70	2231.4	3.30	3.90	5.00	3.90	7.90	0	30.0	3
2	10.38	24.77	1	6.60	11.90	11.50	14.50	10.70	1989.0	3.51	3.90	5.00	3.90	7.90	0	30.0	3
3	16.80	44.91	1	6.60	14.90	11.20	11.20	8.10	1505.7	3.01	3.90	5.00	3.90	7.90	0	30.0	3
4	98.95	27.97	1	6.60	14.90	11.50	11.20	8.10	1505.7	3.14	3.90	5.00	3.90	7.90	0	30.0	3
5	103.92	43.06	1	6.60	14.90	11.50	11.20	8.10	1480.8	3.19	3.90	5.00	3.90	7.90	0	30.0	3
6	47.06	25.96	1	6.60	6.60	4.40	8.60	5.80	1239.7	2.90	3.90	3.10	2.00	7.90	0	30.0	3
7	59.13	18.10	1	6.60	6.60	4.40	8.60	5.80	1239.7	3.13	3.90	3.10	2.00	7.90	0	30.0	3
8	14.64	5.99	1	6.60	6.20	0.20	8.20	7.60	305.9	2.98	3.90	3.10	2.00	7.90	0	30.0	3
9	22.89	26.34	1	6.60	6.40	3.90	7.50	0.50	561.5	2.98	3.90	3.10	2.00	7.90	0	30.0	3
10	18.36	12.41	1	6.60	6.40	3.90	7.50	0.50	561.5	3.56	3.90	3.10	2.00	7.90	0	30.0	3
11	34.61	17.03	1	6.60	6.40	3.90	7.50	0.50	1648.7	3.16	3.90	3.10	2.00	7.90	0	30.0	3
12	19.62	27.37	2	7.49	12.20	7.70	13.50	8.10	12767.6	3.94	3.56	4.50	3.20	7.63	1	30.2	4
13	35.84	35.84	2	7.46	13.50	10.20	16.10	10.90	15078.7	3.14	3.54	4.35	2.80	7.66	1	30.2	4
14	29.42	57.83	2	6.91	16.10	13.40	18.00	13.70	15437.4	3.04	3.76	4.05	2.60	7.42	1	30.9	4
15	7.47	19.00	2	7.47	16.50	13.50	20.10	14.60	18308.7	3.04	4.04	4.05	2.69	7.51	1	31.2	4
16	6.16	7.72	2	7.69	20.10	14.90	20.40	14.90	16000.8	1.60	3.70	3.50	2.40	7.52	1	31.1	4
17	13.89	10.40	2	7.74	20.40	14.90	15.50	14.90	18566.0	1.58	3.44	3.60	2.45	7.68	1	31.3	4
18	3.80	27.60	1	7.10	14.00	11.20	11.60	8.60	1598.3	1.98	11.90	8.81	6.00	7.10	0	10.0	1
19	10.06	4.69	1	7.10	13.40	11.20	11.60	8.60	1620.4	1.71	11.00	8.21	5.82	7.10	3	26.0	1
20	3.24	97.06	2	7.80	21.30	13.60	17.00	13.60	5820.0	3.80	10.60	8.05	5.38	7.80	0	12.7	1
21	14.80	2.28	2	7.80	21.60	13.10	19.30	14.00	6185.0	3.44	10.50	8.72	5.47	7.80	4	35.6	1
22	7.79	6.02	2	7.80	21.30	13.60	19.30	14.00	6587.8	3.73	10.50	8.31	5.34	7.80	3	15.4	1
23	6.14	40.28	2	8.00	18.50	12.90	14.40	12.70	5476.9	1.89	11.30	9.81	6.31	8.00	2	14.9	1
24	2.29	125.02	2	8.00	18.60	13.20	14.50	12.70	5601.5	1.95	11.30	9.81	6.31	8.00	0	17.5	1
25	8.80	20.16	2	8.00	18.60	13.10	14.40	12.70	5139.0	1.84	11.30	9.81	6.31	8.00	3	17.3	1
26	1.42	32.62	2	7.80	27.80	18.90	22.60	20.80	6726.0	1.99	5.13	5.52	3.51	7.80	0	8.4	1
27	5.08	137.76	2	7.30	9.80	2.90	7.70	7.70	1693.9	4.56	8.66	8.16	5.03	7.30	0	15.2	1
28	6.58	7.03	2	7.30	9.80	3.00	7.70	7.70	1759.7	3.42	8.66	8.16	5.03	7.30	2	10.6	1
29	42.45	59.85	2	4.28	11.28	8.26	7.26	6.22	2389.6	1.05	2.56	3.83	3.35	6.25	0	33.3	1
30	10.49	50.33	2	5.14	11.28	8.26	8.26	6.22	1846.3	1.12	3.07	4.60	4.02	7.50	0	40.0	1
31	9.68	65.16	2	5.14	11.28	8.26	7.26	6.22	3335.5	1.18	3.07	4.60	4.02	7.50	0	40.0	1
32	4.89	47.00	2	5.88	13.44	8.51	8.84	8.18	4750.3	1.04	4.01	5.83	4.14	7.44	0	40.0	1
33	16.27	54.06	2	5.88	13.44	8.51	8.84	7.74	4745.7	1.15	4.01	5.83	4.14	7.44	0	40.0	1
34	3.52	39.23	3	5.71	27.33	17.94	17.00	15.88	5690.1	0.95	1.52	4.02	2.00	7.47	0	40.0	1
35	3.81	51.19	3	5.71	27.33	17.94	17.00	15.88	5687.8	0.90	1.52	4.02	2.00	7.47	0	40.0	1
36	2.47	40.76	3	5.71	27.33	17.94	17.00	15.88	5134.7	1.12	1.52	4.02	2.00	7.47	0	40.0	1
37	7.68	29.79	3	5.75	7.76	3.11	5.69	3.30	1311.5	1.12	1.72	4.08	3.71	7.38	0	40.0	1
38	13.20	41.49	3	5.75	7.76	3.11	5.69	3.30	1309.1	1.08	1.72	4.08	3.71	7.38	0	40.0	1
39	10.95	36.62	3	5.75	7.76	3.11	5.69	3.30	890.0	1.21	1.72	4.08	3.71	7.38	0	40.0	1
40	6.05	37.50	3	5.46	6.65	1.62	6.65	1.62	1334.7	1.11	2.06	4.03	3.05	7.45	0	40.0	1
41	4.43	31.85	3	5.46	6.65	1.62	6.65	1.62	1334.7	1.23	2.06	4.03	3.05	7.45	0	40.0	1
42	12.45	48.86	3	5.46	6.65	1.62	0.00	0.00	898.6	0.91	2.06	4.03	3.05	7.45	0	40.0	1
Max.	103.92	137.76	3	8.00	27.80	18.90	22.60	20.80	18566.0	4.56	11.90	9.81	6.31	8.00	4	40.0	4
Min.	1.4248	2.28	1	4.28	6.20	0.20	0.00	0.00	305.9	0.90	1.52	3.10	2.00	6.25	0	8.4	1
Aver.	18.37	37.15	1.90	6.63	13.97	9.26	11.81	8.86	4745.1	2.30	4.96	5.29	3.67	7.60	0.55	29.8	1.95
s.d.	22.792	28.76	0.73	0.95	6.50	5.26	5.15	5.14	5098.6	1.08	3.33	2.12	1.37	0.33	1.04	9.7	1.21

이의 가중치이다. 하첨자 i, j 는 각각 입력변수와 은닉층 뉴런에 대한 지수이다. X_{ij} 값과 은닉층의 각 뉴런에 대한 X_{ij} 합($\sum_{i=1}^3 X_{ij}, 0 \leq j \leq 4$)은 Table A2에 정리되어 있다.

ii) 각 은닉층의 뉴런에 대하여, 가중치 곱(X_{ij})의 합에 대한 X_{ij} 의 비율을 구한다. 이 비율을 Y_{ij} 라고 하면,

$$Y_{ij} = \frac{X_{ij}}{\sum_i X_{ij}}, 0 \leq i \leq 3, 0 \leq j \leq 4 \quad (\text{A3})$$

Table A3은 Y_{ij} 값과 각 입력변수에 대한 Y_{ij} 합($S_i = \sum_{j=1}^4 Y_{ij}, 0 \leq i \leq 3$)을 보여준다.

iii) 마지막으로 S_i 의 상대적 비율을 구하여 각 입력변수에 대한 상대적 중요도(Z_i)를 구한다.

$$Z_i = \frac{S_i}{\sum_i S_i} \quad (\text{A4})$$

이러한 가중치 분할법(weight partitioning method, Garson, 1991)을 이용하여 분석한 결과 본 예제에 대하여 입력변수들의 상대적 중요도는 $p_1 > p_2 > p_3$ 이다.

이 방법은 비교적 단순하며, 효과적으로 입력변수의 중요성을 판단할 수 있지만, 편차(bias)에 대한 분석은 제외되어 있다.

A2. 수치해석에 사용된 실험데이터

(experimental data used for numerical analysis)

Table A4에서는 ALFAM database(Sommer et al., 2001)에서 선별된 실험데이터를 정리 수록하였다.