

인공신경망이론을 사용한 척도인자 예측방법론의 향상 방안

Development for Scaling Factor Using Artificial Neural Network

이상철, 황기하, 이건재
한국과학기술원
대전광역시 유성구 구성동 373-1

요약

원자력 발전소에서 발생하는 방사성폐기물은 폐기물의 물리적, 화학적 특성 뿐만 아니라 폐기물 내에 존재하는 평가대상 핵종들에 대한 농도 및 방사능 정보가 명시되어야만 최종 처분이 가능하다. 하지만, 대부분의 방사성 핵종들의 경우, 측정이 어려울 뿐만 아니라 분석에 많은 비용이 든다. 그래서 제안된 방법이 척도인자 방법이다. 즉 측정이 어려운 방사성 핵종(DTM 핵종)의 농도와 측정이 수월한 핵종(Key 핵종)의 농도 사이의 상관관계(척도인자)를 도출하여, 측정된 Key 핵종의 농도를 통하여 DTM 핵종의 농도를 예측하게 된다. 척도인자를 도출하는 일반적 방법으로 로그 평균 방법(Log Mean Average : LMA)이 사용되고 있다. 하지만, 이 방법을 사용할 경우, 핵분열 생성 핵종들과 일부의 부식 생성 핵종들에서는 예측한 값과 실제 값이 차이가 많이 나는 것이 일반적 경향이다. 그래서 본 연구에서는 C-14, Sr-90, I-129의 세 핵종들에 대해서, 인공신경망이론(Artificial Neural Network : ANN)을 사용한 척도인자 모델과 LMA를 사용한 척도인자 모델을 비교하였다. 세 핵종 모두에서 ANN을 사용한 모델이 LMA를 사용한 모델에 비하여 예측의 정확성이 높았다. LMA를 사용하여 예측 모델을 구성하였을 때, 적절한 농도의 예측치를 얻을 수 없는 DTM 핵종들의 경우, ANN을 사용한 예측 모델을 통해서 예측의 정확성을 높일 수 있음을 알 수 있었다.

Abstract

Final disposal of radioactive waste generated from Nuclear Power Plant(NPP) requires the detailed knowledge of the natures and quantities of radionuclides in waste package. Many of these radionuclides are difficult to measure and expensive to assay. Thus it is suggested to the indirect method by which the concentrations of DTM

(Difficult-to-Measure) nuclide is decided using the relation of concentrations (Scaling Factor) between Key(Easy-to-Measure) nuclide and DTM nuclide with detected concentrations of Key nuclide. In general, scaling factor is determined by using of log mean average(LMA). This method is easy to use. But in case of fission product nuclides and other nuclides, the predicted values isn't well matched with the original values. In this study, the method using ANN for C-14, Sr-90 and I-129 are compared with that using LMA. For all of three nuclides, the predicted values using ANN are well matched with the original values compared with that using LMA. It is concluded that the predicted values of the concentration of DTM nuclide can be improved by the model using ANN when the predicted values of them are not well matched by the model using LMA.

1. 서론

원자력 발전소에서 발생하는 방사성폐기물은 궁극적으로 처분장으로 수송되어 처분되어 진다. 수송 및 처분 안전성을 위해, 원자력 발전소에서 발생하는 방사성폐기물은 폐기물의 물리적, 화학적 특성뿐만 아니라 폐기물 내에 함유된 규명 대상 핵종에 대한 농도 및 방사능 정보가 명시되어야만 처분장으로 이송이 가능하다. 하지만, 대부분의 방사성 핵종들의 경우, 측정이 어려울 뿐만 아니라, 분석 시 많은 노력과 경비가 소요된다. 따라서 미국을 포함한 여러 나라에서는 자국의 분류 기준에 명시된 핵종들의 농도를 간접적인 방법으로 결정하는 것을 허용하고 있다. 여기서, 말하는 간접적 방법이란 척도 인자(Scaling Factor)를 이용하는 것을 의미하는데, 측정이 쉬운 감마 방출 핵종들(Key 핵종)의 농도를 통하여 측정이 어려운 알파 또는 베타 핵종(DTM 핵종)의 농도를 예측하는 방법이다. 척도인자는 DTM 핵종과 Key 핵종 사이의 간단한 상수로 표현되는 농도비를 의미하기도 하지만, 본 연구에서 척도인자는 DTM 핵종의 농도를 예측하기 위한 Key 핵종과 DTM 핵종 사이에서 나타나는 관계식을 의미한다.

일반적으로 척도인자는 시료 샘플의 방사화학 분석을 통하여 얻어진 시료 샘플 데이터의 통계처리를 통하여 도출되어 진다. 본 연구에서 사용될 시료 샘플 데이터는 EPRI NP-4037에 나타난 데이터를 사용하였다[1].

시료 샘플 데이터의 통계처리를 위한 일반적으로 사용되는 방법으로는 로그 평균(LMA)을 이용하고 있다. 하지만, 이 방법은 척도인자를 도출하기는 쉽지만, 핵분열 생성 핵종들과 일부의 부식 생성 핵종들의 경우, 이 방법을 통하여 예측한 값과 실측된 값에 차이가 많이 난다. 일반적으로 C-14, Sr-90, I-129는 로그 평균 방법(LMA)을 통하여 예측하기 어려운 핵종들로서 알려져 있다. 본 연구에서는 C-14,

Sr-90, I-129 위의 세 핵종들에 대해서, 인공신경망이론(ANN)을 사용한 척도인자 모델과 로그 평균 방법(LMA)을 사용한 척도인자 모델을 비교하였다. 이를 통하여 ANN의 척도인자에 대한 적용가능성을 살펴보았다.

2. 로그 평균 방법(Log Mean Average)

로그 평균 방법론은 수학적 모델이 단순하여 방법론의 적용이 용이하고, 모델을 구성하는 parameter가 하나이므로, 별도의 그래프나 분석 없이도 모델 식만을 통해 DTM 핵종과 Key 핵종 간의 농도 관계를 쉽게 파악할 수 있다. 하지만, 로그 변환 후의 DTM 핵종 농도와 Key 핵종 농도가 선형적 관계가 적을 경우, Key 핵종 농도를 통하여 예측한 DTM 핵종 농도는 실제 값과 차이가 크다. 식 (1)과 식 (2)에 로그 평균을 이용한 방법을 나타내었다.

$$A_{RN} = C \times A_{KN} \quad \text{-----} \quad (1)$$

A_{RN} : 예측한 DTM 핵종의 방사능

A_{KN} : 계측된 Key 핵종의 방사능

C : 미리 결정된 방사능 비(척도인자)

$$C = \exp \left\{ \frac{1}{N} \sum_{i=1}^N \ln \left(\frac{A_{RNi}}{A_{KNi}} \right) \right\} \quad \text{-----} \quad (2)$$

A_{RNi} : 시료 i에서 계측된 DTM 핵종의 방사능

A_{KNi} : 시료 i에서 계측된 Key 핵종의 방사능

로그 평균 방법론을 평가하는 척도로는 Log Mean Dispersion(LMD)을 주로 활용한다. LMD는 $\ln(A_{RNi}/A_{KNi})$ 의 표준편차에 다시 역로그를 취하여 구해진다. LMD값이 작을수록, 도출된 척도인자가 적합하다고 판단할 수 있다. 하지만 본 연구에서는 ANN와 비교하기 위해 로그 평균 방법론을 평가하는 척도로서 LMD를 사용하지 않고, DTM 핵종 농도의 예측한 값과 실제 값을 로그 변환한 후, 두 값의 평균제곱오차의 제곱근(Root Mean Squared Error : RMSE)을 구하여 평가하였다. RMSE의 도출시, 예측한 값과 실제 값을 로그 변환하는 이유는 핵종들의 농도의 Order 범위가 광범위해서, 로그 변환을 하지 않으면 Order가 큰 몇 개의 시료 데이터에 의해서도 전체 RMSE에 큰 영향을 미칠 수 있기 때문이다. 식 (3)은 RMSE를 나타낸다 [2].

$$RMSE = \sqrt{\frac{\sum_{i=1}^N \{Ln(A_{pDi}) - Ln(A_{OGi})\}^2}{DF}} \quad \text{-----} \quad (3)$$

A_{pDi} : 시료 i에서 예측된 DTM 핵종의 방사능

A_{OGi} : 시료 i에서 실측된 DTM 핵종의 방사능

DF : 전체 시료 데이터의 자유도(degree of freedom)

3. 인공신경망이론(Artificial Neural Network)

신경망 또는 인공신경망에 관한 연구는 뇌신경생리학(neurophysiology)으로부터 영감을 얻어 시작되었다. 자료 분석분야에서 신경망은 복잡한 구조를 가진 자료에서의 예측(prediction) 문제를 해결하기 위해서 사용되는 유연한 비선형모형(nonlinear models)의 하나로 분류될 수 있다. 신경망은 은닉마디(hidden units)라고 불리는 독특한 구성요소에 의해서 일반적인 통계모형과 구별되어진다. 은닉마디는 인간의 신경세포를 모형화한 것으로써, 각 은닉마디는 입력변수들의 결합(combination)을 수신하여 목표변수에 전달한다. 이 때 결합에 사용되는 계수들을 연결강도(synaptic weights)라고 부르며, 활성화함수는 입력값을 변환하고 이를 입력으로 사용하는 다른 마디로 출력하게 된다.[3]

신경망에는 여러 가지 다양한 모형이 있으나, 그 중에서도 자료 분석을 위해 가장 널리 사용되는 모형은 MLP(Multilayer Perceptron) 신경망이다. 그림 1.은 입력층, 두 개의 은닉마디로 이루어진 하나의 은닉층과 하나의 출력층으로 이루어진 MLP 신경망의 구조를 나타낸다. 식 (4)는 이를 수식으로 도식화한 것이다[4].




그림 1. MLP의 구조

$$\begin{aligned}
H_1 &= f_1(b_1 + w_{11}X_1 + w_{21}X_2 + \cdots + w_{p1}X_p) \\
H_2 &= f_2(b_2 + w_{12}X_1 + w_{22}X_2 + \cdots + w_{p2}X_p) \\
Y &= g(b_0 + w_{10}H_1 + w_{20}H_2)
\end{aligned} \tag{4}$$

- 입력층 : 각 입력변수에 대응되는 마디들로 구성되어 있다. 본 연구에서는 입력 변수로 발전소번호, 폐기물 스트림, Co-60의 농도, Cs-137의 농도를 사용하였다.
- 은닉층 : 여러 개의 은닉마디로 구성되어 있다. 각 은닉마디는 입력층으로부터 전달되는 변수값들의 선형결합(linear combination)을 비선형함수(nonlinear function)로 처리하여 출력층 또는 다른 은닉층에 전달한다. 본 연구에서는 1개의 은닉층과 10개의 은닉마디로 MLP 신경망을 구성하였다.
- 출력층 : 목표변수(target)에 대응하는 마디들을 갖는다. 본 연구에서는 목표변수로 DTM 핵종 농도를 사용하였다.
- 결합함수(combination function) : 결합함수는 입력층 또는 은닉층의 마디들을 결합하는 형태를 의미한다. 예를 들어, 식 (4)에서 각 은닉마디 $H1$ 과 $H2$ 는 입력변수들을 선형결합(즉, $b_j + w_{1j}X_1 + w_{2j}X_2 + \cdots + w_{pj}X_p$)하여 이를 변환한다. 본 연구에서도 결합함수로 선형함수(linear function)를 사용하였다.
- 활성화함수(activation function) : 입력 변수 또는 은닉마디의 결합을 변화하는 함수를 의미한다. 식 (4)에서 $f1$, $f2$ 와 g 는 각각 활성화함수와 출력활성함수라고 한다. 본 연구에서는 활성화함수로 쌍곡탄젠트(hyperbolic tangent)함수를 사용하였다. 쌍곡탄젠트 함수는 식 (5)와 같다.

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \tag{5}$$

4. LMA와 ANN을 사용한 척도인자 모델 비교

LMA를 사용한 모델에서는 Co-60과 Cs-137 각각을 Key 핵종으로 선정한 2개의 예측 모델을 구성하였다. 폐기물 스트림별로 나누어 각각의 척도인자를 도출한 후, 이를 통하여 DTM 핵종의 농도를 예측하였다. ANN을 사용한 모델의 경우, ANN에 관한 사항을 정리하면 표 1. 과 같다.[5]

표 1. 신경망이론을 사용한 척도인자 모델

신경망 모형	MLP 신경망
입력변수	발전소번호, 폐기물스트림, Co-60의 농도, Cs-137의 농도 (4개)
은닉층	10개의 은닉마디로 구성된 1개의 은닉층
출력층	DTM 핵종(C-14, Sr-90, I-129)의 농도(1개)
결합함수	선형함수(linear function)
활성함수	쌍곡탄젠트(hyperbolic tangent) 함수

4.1 C-14

그림 2. 는 Key 핵종으로 각각 Co-60과 Cs-137을 선정한 LMA를 사용한 2개의 모델과 ANN을 사용한 모델에서 C-14의 예측 농도와 실측 농도에 대한 산점도를 나타낸 것이다. 표 2. 는 각 모델의 RMSE를 비교한 것으로 식 (3)을 통하여 도출하였다.




그림 2. 예측 모델에 따른 C-14 농도의 예측한 값과 실제 값의 산점도

표 2. 예측 모델에 따른 RMSE 비교(C-14)

예측 모델	RMSE
LMA(Key 핵종 : Co-60)	3.234
LMA(Key 핵종 : Cs-137)	3.229
ANN	0.398

4.2 Sr-90

그림 3. 은 Key 핵종으로 각각 Co-60과 Cs-137을 사용하여 구한 LMA를 사용한 2개의 모델과 ANN을 사용한 모델에서 Sr-90의 예측 농도와 실제 농도에 대한 산점도를 나타낸 것이다. 표 3은 각 모델의 RMSE를 비교한 것이다.




그림 3. 예측 모델에 따른 Sr-90 농도의 예측한 값과 실제 값의 산점도

표 3. 예측 모델에 따른 RMSE 비교(Sr-90)

예측 모델	RMSE
LMA(Key 핵종 : Co-60)	3.099
LMA(Key 핵종 : Cs-137)	3.197
ANN	0.826

4.3 I-129

그림 4. 는 Key 핵종으로 각각 Co-60과 Cs-137을 선정한 LMA를 사용한 2개의 모델과 ANN을 사용한 모델에서 I-129의 예측 농도와 실측 농도에 대한 산점도를 나타낸 것이다. 표 4. 은 각 모델의 RMSE를 비교한 것이다.




그림 4. 예측 모델에 따른 I-129 농도의 예측한 값과 실제 값의 산점도

표 4. 예측 모델에 따른 RMSE 비교(I-129)

예측 모델	RMSE
LMA(Key 핵종 : Co-60)	4.532
LMA(Key 핵종 : Cs-137)	4.278
ANN	0.725

5. 결론

C-14, Sr-90, I-129 세 핵종 모두에서 LMA를 사용한 예측 모델에 비해 ANN을 사용한 예측 모델이 예측의 정확성 측면에서 크게 향상되었음을 알 수 있다. 특히 I-129의 경우, LMA를 사용한 예측 모델의 경우, 예측한 값과 실제 값과의 오차가 커서 예측 모델을 사용할 수 없을 것으로 판단되어지는데 비해 ANN을 사용한 예측모델을 통하여 예측한 값은 실측값과의 오차가 매우 적었다. 이처럼 기존의 통계 처리 방법인 LMA를 사용한 예측 모델을 구성하였을 때, 적절한 농도의 예측치를 얻을 수 없는 DTM 핵종들의 경우, ANN을 사용한 예측 모델을 통해서 예측치를 증진시킬 수 있을 것으로 판단되어 진다. LMA를 사용한 예측 모델이 로그 변환 후의 DTM 핵종 농도와 Key 핵종 농도가 선형적 관계가 있음을 가정하여 예측치를 도출하기 때문에 두 핵종의 선형적 관계가 적을 경우, 예측의 정확성의 떨어지지만, ANN을 사용한 예측 모델의 경우 두 핵종의 선형성을 기반으로 하지 않는 비선형 모델이기 때문에 두 핵종의 선형적 관계가 적더라도 예측의 정확성을 유지할 수 있다고 판단되어 진다.

감사의 글

본 연구는 한국수력원자력(주) 원자력환경기술원의 “척도인자 운영프로그램 및 기존드럼 핵종분석방법 개발”의 일환으로 수행되었습니다.

참고 문헌

- [1]. EPRI NP-4037, "Radionuclide Correlations in Low-Level Radwaste" (1985)
- [2]. Anthony J.Hayter, "Probability and Statistics for Engineers and Scientists", pp 550-565, Duxbury(2002)
- [3]. 강현철 외 4인, "SAS Enterprise Miner를 이용한 데이터마이닝", pp 233-240, 자유아카데미(2000)
- [4]. 김대수, "신경망 이론과 응용", 하이테크정보(1992)
- [5]. 최국렬·조대현, "SAS언어와 데이터 분석", pp 161-168, 교우사(2001)