

## 인공신경망을 이용한 주조 스테인리스강의 열취화 민감도 평가

김 철\* · 박흥배\* · 진태은\*\* · 정일석\*\*\*  
(2003년 8월 22일 접수, 2004년 2월 24일 심사완료)

### Evaluation of Thermal Embrittlement Susceptibility in Cast Austenitic Stainless Steel Using Artificial Neural Network

Cheol Kim, Heung-Bae Park, Tae-Eun Jin and Ill-Seok Jeong

**Key Words :** Thermal Embrittlement(열취화), Cast Austenitic Stainless Steel(주조 오스테나이트 스테인리스강), Ferrite Content(페라이트 함량), Artificial Neural Network(인공신경망)

#### Abstract

Cast austenitic stainless steel is used for several components, such as primary coolant piping, elbow, pump casing and valve bodies in light water reactors. These components are subject to thermal aging at the reactor operating temperature. Thermal aging results in spinodal decomposition of the delta-ferrite leading to increased strength and decreased toughness. This study shows that ferrite content can be predicted by use of the artificial neural network. The neural network has trained learning data of chemical components and ferrite contents using backpropagation learning process. The predicted results of the ferrite content using trained neural network are in good agreement with experimental ones.

#### 1. 서론

원전 설비중 1차측 압력경계 기기는 원자로냉각재의 유로 제공과 압력경계 유지 기능을 수행하기 때문에 방사성 물질의 오염 및 확산을 방지하는데 있어서 매우 중요하다. 이에 따라 1차측 압력경계 기기에는 부식 저항성과 기계적 성질이 우수한 주조 스테인리스강(CASS, cast austenitic stainless steel)이 많이 사용되고 있다. 주조 스테인리스강은 페라이트와 오스테나이트의 2상(duplex)으로 구성되어 있으며 구성비율은 화학조성에 의해 결정된다. 화학조성 중 크롬(Cr), 실리콘(Si), 몰리브덴(Mo), 나이오비움(Nb) 등은

페라이트 형성을 촉진시키는 인자이며, 니켈(Ni), 망간(Mn), 질소(N), 탄소(C) 등은 오스테나이트의 형성을 촉진시키는 인자이다.<sup>(1)</sup> 주조 스테인리스강의 등급은 CF-3, CF-8, CF-3M, CF-8M, CF-3A, CF-8A 등으로 나뉘는데 등급 기호의 첫 번째 문자 C는 부식저항성(corrosion resistance)을 의미하며, 두 번째 문자 F는 니켈과 크롬의 비율을 A-Z로 나타내었을 때 F번째에 해당한다는 것을 의미한다. 또한 숫자 3은 최대 탄소 함유량이 0.03wt%, 숫자 8은 0.08wt%임을 뜻한다.<sup>(2)</sup>

주조 스테인리스강은 뛰어난 부식저항성이 있는 반면 고온에서 장시간 사용될 경우 열취화가 발생하는 단점이 있다. 열취화 현상은 주조 스테인리스강이 고온에 장시간 노출되었을 때 페라이트상에서 복잡한 상변화가 발생하여 취화되는 것으로서, 일반적으로 인장강도는 다소 증가하나 충격강도와 파괴인성은 상당한 수준으로 저하된다. 이러한 열취화는 페라이트상에서 발생하기 때문에 페라이트 함량이 많을수록 열취화가 크게 발생한다. 따라서 열취화 평가에 있어서 재

† 책임저자, 회원, 한전기술(주) 재료기술연구그룹  
E-mail : chlkim@kopec.co.kr  
TEL : (031)289-4682 FAX : (031)289-3189

\* 한전기술(주) 재료기술연구그룹

\*\* 회원, 한전기술(주) 재료기술연구그룹

\*\*\* 회원, 전력연구원 원자력연구실

료의 페라이트 함량을 정확하게 평가하는 것은 매우 중요하다.

현재 페라이트 함량 평가에 있어서는 Aubrey<sup>(3)</sup>나 Schoefer<sup>(4)</sup> 등이 제안한 예측식을 이용하거나 자성인 페라이트의 성질을 이용한 자기측정법<sup>(4)</sup>이 많이 사용되고 있다. 그러나 실제 원전 기기의 열취화 민감도 평가시 예측식으로 계산한 값과 측정값과의 차이가 비교적 크게 발생하고 있어 민감도 평가에 어려움이 따른다.

Table 1은 Aubrey의 예측식과 자기측정 장비를 이용한 페라이트 함량 측정결과<sup>(5)</sup>를 비교하여 나타낸 것으로서, 예측값과 측정값의 차이가 50%까지 발생하는 것을 볼 수 있다. 이러한 차이는 측정방법의 정밀도나 정확도에도 원인이 있겠지만, Aubrey 예측식이 40여개 시편의 측정결과와 수치해석적인 상관관계로부터 예측식을 구하여 예측식 자체의 정확도에도 그 원인이 있다. 또한 Fig. 1은 크롬당량과 니켈당량의 비로부터 페라이트 함량을 구하기 위한 Schoefer 선도<sup>(4)</sup>를 나타낸 것으로서, 그림에서 상한과 하한 사이의 밴드 폭이 상당히 큰 것을 볼 수 있다. 예를 들어 당량비가 1.4인 경우 예측되는 페라이트 함량의 범위는 약 15-28Vol.%인 바, 예측되는 페라이트 함량의 범위가 매우 큰 것을 알 수 있다.

한편, 페라이트 함량은 재료의 화학조성에 의해 결정되기 때문에 7-10 가지의 화학조성에 의해 결정되는 다변수 문제에 해당된다. 이러한 다변수 문제의 결과예측을 위한 알고리즘 중에서, 인공신경망은 정확하면서 충분한 양의 학습데이터가 확보되는 경우 효과적으로 결과를 예측하는 것으로 알려져 있다.

따라서 본 연구에서는 인공신경망을 이용하여 페라이트 함량 예측방법을 제시하고 그 효용성을 검증하였으며, 이를 국내 원전 1차계통 배관에 적용하여 열취화 민감도 평가를 수행하였다.

## 2. 열취화 민감도 기준

주조 스테인리스강의 열취화 민감도에 대해서는 일반적으로 미국 원자력규제위원회(USNRC)에서 발행한 GALL 보고서<sup>(6)</sup>의 기준을 따르고 있다. 주조방식, 몰리브덴 함량 및 페라이트 함량에 기초하여 주조 스테인리스강 기기의 열취화에 대한 민감도를 결정하고 잠재적으로 열취화에 민감한

Table 1 Calculated and measured ferrite content

Cr	Mo	Si	Ni	Mn	C	N	$\delta_c$ (Vol.%)		Err (%)
							Aubrey eq.	Meas.	
19.49	0.35	0.92	9.40	0.57	0.009	0.052	10.3	13.5	23.7
19.81	0.59	1.06	10.63	0.60	0.018	0.028	8.4	16.3	48.5
20.18	0.34	1.13	8.59	0.63	0.023	0.028	21.0	23.6	11.0
19.11	2.51	0.73	9.03	0.54	0.064	0.048	15.5	18.4	15.8
20.86	2.58	0.67	9.12	0.53	0.065	0.052	24.8	27.8	10.8




Fig. 1 Schoefer diagram for estimation of ferrite content

것으로 판정된 기기에 대해서는 파괴역학적인 결함평가를 수행해야 한다. 그러나 열취화에 민감하지 않은 것으로 판명된 기기에 대해서는 추가적인 검사나 평가가 필요하지 않다.

주조 스테인리스강으로 제작된 기기의 열취화 민감도 평가기준은 재료의 페라이트 함량에 의해 결정되며, 250℃ 이상의 온도에서 운전되는 모든 압력경계 기기 및 원자로 내부구조물 기기에 적용된다. Table 2는 GALL 보고서에서 제시한 열취화 민감도 평가기준을 정리한 것으로서 주조방법 및 몰리브덴 함량에 따라 페라이트 함량에 의해 주조 스테인리스강의 열취화 민감도를 결정할 수 있다. 몰리브덴 함량이 낮은 경우(최대 0.5wt.%)에는 정적주조(static cast)품이고 페라이트 함량이 20%를 초과할 때 열취화에 민감하며, 몰리브덴 함량이 높은 경우(2.0-3.0 wt.%)에는 정적주조품이고 페라이트 함량이 14%를 초과하는 경우와, 원심주조(centrifugal method)품이고 페라이트

**Table 2** Screening criteria thermal embrittlement susceptibility in GALL report

Mo content	Casting method	Ferrite content, $\delta_c$ (Vol.%)	Susceptibility
High Mo (2-3 wt%)	Static	$\delta_c > 14$	Potentially susceptible
	Centrifugal	$\delta_c > 20$	Potentially susceptible
Low Mo (max 0.5wt%)	Static	$\delta_c > 20$	Potentially susceptible
	Centrifugal	All	Not susceptible

트 함량이 20%를 초과할 때 열취화에 민감하다. 이와 같은 기준을 적용하였을 때 열취화에 민감한 것으로 평가된 기기에 대해서는 ASME Sec. XI에 제시된 방법에 따라 파괴역학적인 결함평가를 수행해야 한다.

### 3. 인공신경망

인공신경망<sup>(7)</sup>은 인간의 뇌가 정보를 인식하고 학습하는 과정을 수학적으로 모델링한 것으로서 뇌의 학습방식과 유사한 신경망학습(neural network training)을 수행한다. 학습 데이터를 신경망에 입력값으로 제시하고 이들 입력값을 신경망에 반복적으로 학습시키면 신경망은 입력값에 맞게 학습된다. 학습이 성공적으로 완료되면 시험예를 학습된 신경망에 대입하며 신경망은 이에 대한 적절한 예측결과를 제시한다.

역전파 신경망(backpropagation neural network)은 Rumelhart 등<sup>(8)</sup>에 의해 제시된 신경망 모델로서 현재 가장 많이 사용되고 있는 학습모델 중 하나이다. 이 모델은 입력층(input layer), 은닉층(hidden layer) 및 출력층(output layer)으로 구성되어 있으며 필요에 따라 여러 개의 은닉층을 사용할 수 있으나 1개의 은닉층만으로도 충분하다고 알려져 있다. 신경망의 각 층은 다수의 유닛들로 구성되어 있으며 각층 사이의 유닛과 유닛들은 연결강도(weight)로 연결되어 있다. 식 (1)은 이러한 연결강도의 조절규칙을 수식으로 나타낸 것이다.

$$w_{jk}(new) = w_{jk}(old) + \alpha \delta_k z_j + \mu \Delta w_{jk}(old) \quad (1)$$

여기서,  $\delta_k = (T_k - O_k)f'(O_{in_k})$

식 (1)에서  $w_{jk}$ 는  $j$ 번째 유닛에서  $k$ 번째 유닛으로의 연결강도이며  $\Delta w_{jk}$ 는 연결강도의 변화량이다.  $z_j$ 는  $j$ 번째 은닉층 유닛의 출력이고  $T_k$ ,  $O_k$ 는 각각  $k$ 번째 유닛의 목표값과 출력값이며  $O_{in_k}$ 는  $k$ 번째 출력층 유닛의 입력값이다.  $f'(O_{in_k})$ 는  $k$ 번째 유닛에서 활성화함수(activation function)의 미분값으로서, 본 연구에서는 활성화함수로 식 (2)와 같이 표현되는 시그모이드 함수(sigmoid function)를 사용하였다.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

또한, 학습률(learning rate)  $\alpha$ 는 신경망의 학습속도를 조절하며, 모멘텀 계수(momentum parameter)  $\mu$ 는 신경망 학습이 지역최소점(local minimum)에 빠지는 것을 방지하고 학습 속도를 향상시킨다. 한편, 각 유닛에 대한 목표값과 출력값의 차이는 오차함수  $E(w)$ 로 정의되며 식 (3)과 같이 표현된다.

$$E(w) = \frac{1}{2} \sum_{k=1}^m (T_k - O_k)^2 \quad (3)$$

결과적으로 신경망 학습은 식 (3)의 오차함수를 최소화하는 방향으로 연결강도를 조절하는 것으로서, 이를 위하여 급강하경사법(steepest gradient descent method)을 이용하며, 출력값이 목표값에 근사하게 되어 학습오차가 규정치보다 작아지면 학습이 종료된다.

본 연구에서는 Visual FORTRAN 6.0으로 작성한 역전파 신경망 학습 프로그램을 이용하여 신경망 학습을 수행하였다.

### 4. 페라이트 함량 예측을 위한 신경망 학습

#### 4.1 신경망 모델 및 학습데이터

페라이트 함량 예측을 위한 신경망 모델은 Fig. 2와 같이 구성하였다. 입력층은 페라이트 생성을 촉진시키는 크롬, 몰리브덴, 실리콘과 오스테나이트 생성을 촉진시키는 니켈, 망간, 질소, 탄소 등 총 7개 유닛을 사용하였으며, 출력층은 페라이트 함량  $\delta_c$ (Vol%) 1개 유닛을 사용하였다.

신경망 학습 데이터는 Aubrey의 측정결과<sup>(3)</sup>와 Chopra의 측정결과<sup>(5)</sup>로부터 수집한 97개의 화학




Fig. 2 Architecture of neural network for prediction of ferrite content in CASS material




Fig. 3 Results of sensitivity analysis for ferrite content

조성 및 페라이트 함량을 이용하였다. Aubrey 측정결과는 43개 시편에 대한 화학조성과 페라이트 함량으로서 식 (4)와 같은 Aubrey의 페라이트 함량 예측식 산출에 사용된 값이다. Fig. 3은 식 (4)의 입력변수를 70-130%까지 변화시키면서 각 화학조성이 페라이트 함량에 미치는 영향을 분석한 결과이다. 그림에서 페라이트 함량은 크롬과 니켈의 변화에 가장 크게 영향을 받는 것을 알 수 있다.

$$\delta_c = 100.3(Cr_{eq}/Ni_{eq})^2 - 170.72(Cr_{eq}/Ni_{eq}) + 74.22 \quad (4)$$

여기서,

$$Cr_{eq} = Cr + 1.21Mo + 0.48Si - 4.99$$

$$Ni_{eq} = Ni + 0.11Mn - 0.0086Mn^2 + 18.4N + 24.5C + 2.77$$

한편 Aubrey의 측정데이터는 페라이트 함량을 가장 정확히 측정할 수 있는 방법으로 알려진 금속조직시험(metallographic point count examination)




Fig. 4 Input data for network training




Fig. 5 Target data for network training

으로 측정된 것으로서 3개 연구기관<sup>(3)</sup>에서 round-robin 방식 실험을 통하여 측정값의 정확도를 높였다. 또한 Chopra의 측정결과는 Chopra의 충격에너지 예측식과 파괴저항선도(J-R curve) 예측식<sup>(5)</sup>의 유도에 사용된 데이터이다. Fig. 4는 입력값인 97개 재료의 화학조성을 나타낸 것이며, Fig. 5는 Fig. 4와 같은 화학조성에 대한 페라이트 함량 측정값을 나타낸 것이다. 따라서 Fig. 4와 같은 화학조성이 입력되었을 때 Fig. 5와 같은 페라이트 함량이 나오도록 신경망 학습이 수행되었다. 학습 데이터의 재료등급별 구성은 CF-3 21개, CF-8 33개, CF-8M 43개로서 CF-8M 재료의 데이터가 상대적으로 많았다.

신경망 학습 조건으로 은닉층 유닛은 20개, 학습률은 0.1, 모멘텀 계수는 0.8로 하였으며 평균 오차 SSE(sum squared error)가 0.0001에 도달하게




Fig. 6 Sum squared error versus training number

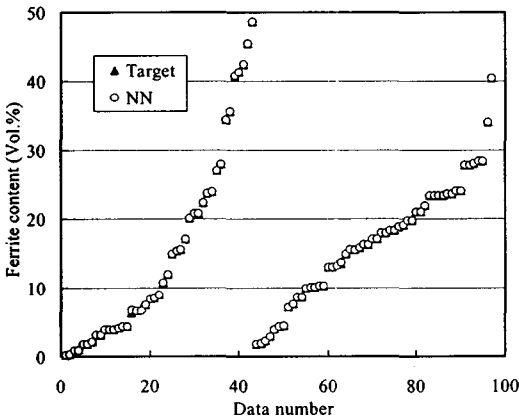


Fig. 7 Comparison between network output and target one

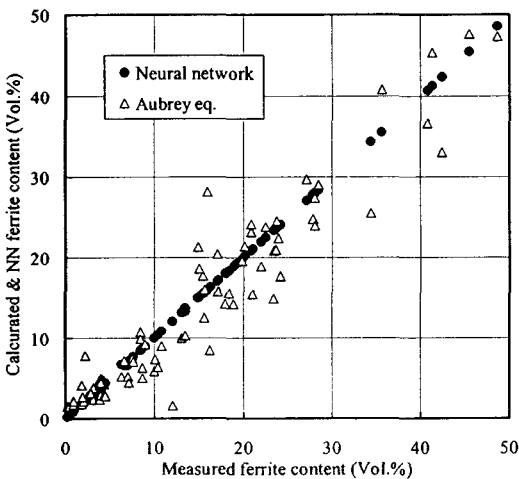


Fig. 8 Comparison between network output and Aubrey equation

나 반복회수가 10만회에 도달하면 학습을 종료하도록 하였다. 또한 은닉층 유닛의 개수는 시행착오를 통하여 가장 적은 학습회수에서 목표오차에 도달할 수 있는 개수를 구하여 적용하였다.

4.2 신경망 학습 결과

Fig. 6은 신경망 학습 종료시까지 학습회수에 따른 평균오차를 나타낸 것으로서 약 9만회의 반복학습 후에 평균오차가 목표하는 값에 도달하였다. 신경망 학습의 성공여부는 신경망 출력층에서 각 유닛의 출력값과 목표값의 차이를 비교하여 판단할 수 있다.

Fig. 7은 신경망 학습이 완료된 이후에 Fig. 5의 목표값(Target)과 신경망 출력값(NN)을 함께 나타낸 것이다. 그림에서 97개의 출력값 모두 목표값과 잘 일치하고 있는 바, 신경망 학습이 성공적으로 이루어졌음을 알 수 있다. 이와 같은 학습 결과는 최소제곱법에서 결정계수  $R^2$ 이 1에 가까운 곡선적합이 이루어진 것과 같다고 할 수 있다.

Fig. 8은 신경망 학습에 사용한 페라이트 함량 측정값에 대하여 Aubrey식의 예측값과 신경망 출력값을 비교하여 나타낸 것이다. 그림에서 Aubrey 예측값은 측정값과의 차이가 큰 반면 신경망 출력값은 측정값과 잘 일치하고 있음을 알 수 있다. 따라서 본 연구에서 학습된 신경망을 이용하여 정확하면서 간편한 방법으로 페라이트 함량을 예측할 수 있을 것으로 판단된다.

5. 페라이트 함량 예측 및 열취화 민감도 평가

신경망 학습이 성공적으로 완료된 후 임의의 입력값을 학습된 신경망에 대입하면 신경망은 이에 대한 적절한 예측 결과를 제시한다. 따라서 본 연구에서는 학습된 신경망에 기존의 연구에서 측정된 화학조성을 적용하여 신경망 예측값과 페라이트 함량 측정값을 비교하는 방법으로 신경망을 이용한 페라이트 함량 예측결과를 검증하였다.

신경망의 검증에는 KRB와 Ringhals 원전에서 실측한 데이터<sup>9)</sup>를 사용하였는데, Table 3은 검증을 위하여 사용한 입력 데이터이며 Table 4는 예측식과 학습된 신경망으로부터 구한 페라이트 함량을 비교하여 나타낸 것이다. Table 4에서 페라

**Table 3** Input data for prediction of ferrite content using trained neural network

Mat.	Cr	Mo	Si	Ni	Mn	C	N
KRB pump cover	21.99	0.17	1.17	8.03	0.31	0.062	0.038
Ringhals Reactor Elbow hot leg	20.00	2.09	1.03	10.60	0.77	0.037	0.044
Ringhals Reactor Elbow cold leg	19.60	2.08	1.11	10.50	0.82	0.039	0.037

**Table 4** Prediction of ferrite content using trained neural network

Material	Ferrite content $\delta_c$ (Vol.%)			
	Meas.	Aubrey eq. (%Err)	Schoefer eq. (%Err)	NN (%Err)
KRB pump cover	34.0	27.7 (18.5)	22.7 (33.2)	33.0 (2.9)
Ringhals Reactor Elbow hot leg	20.1	13.0 (35.3)	13.1 (34.8)	20.6 (2.4)
Ringhals Reactor Elbow cold leg	19.8	12.3 (37.9)	12.9 (34.8)	18.3 (7.5)

이트 함량 측정값과 Aubrey 및 Schoefer 예측식의 결과는 비교적 큰 차이가 있으나, 인공신경망으로부터 예측한 페라이트 함량은 측정값과 잘 일치하였다. 특히 정적주조로 제작된 엘보우의 경우, Aubrey식과 Schoefer식의 결과는 열취화 민감도 평가 기준인 14Vol.%보다 낮아 열취화에 민감하지 않은 것으로 판정되는데 반해 실측 결과는 기준을 초과하는 바, 예측식을 이용할 경우 비보수적으로 열취화 민감도 평가가 이루어질 수 있다. 그러나 본 연구결과를 이용하여 예측한 페라이트 함량은 측정값과 근사하므로 기기의 보수적인 건전성평가 측면에서도 바람직한 것으로 판단된다.

따라서 본 연구결과를 이용하면 간편하면서도 기존 방법보다 정확하게 페라이트 함량을 예측할 수 있으며, 이를 이용하여 열취화 민감도 평가를 수행할 수 있다. 또한 학습을 위한 측정데이터를 추가한다면 보다 더 정확한 예측이 가능하며, 향후 충격에너지, 인장특성 등의 재료물성치 예측으로 확장할 수 있을 것으로 판단된다.

인공신경망을 이용한 페라이트 함량 예측결과를 검증하였으므로 같은 방법을 국내 원전 1차계

**Table 5** Chemical composition of primary piping in a domestic power plant

Position	Cr	Mo	Si	Ni	Mn	C	N
Hot leg	19.1	2.56	0.47	9.68	0.88	0.06	0.04
Cold leg	20.0	2.40	0.66	9.71	1.03	0.05	0.04
Crossover leg	19.4	2.50	0.50	9.63	0.81	0.06	0.04
90° Elbow1	19.4	2.15	1.15	9.75	0.51	0.06	0.04
90° Elbow2	19.6	2.15	1.12	9.55	0.50	0.05	0.04
50° Bend	19.2	2.20	1.00	9.55	0.44	0.05	0.04
35° Bend1	19.1	2.15	1.10	9.65	0.51	0.05	0.04
35° Bend2	19.4	2.40	1.35	9.42	0.51	0.06	0.04

**Table 6** Susceptibility evaluation of thermal embrittlement in a domestic power plant

Position	Casting method	$\delta_c$ (Vol.%)			Susceptibility
		CMTR	Aubrey eq.	NN	
Hot leg	Centrifugal	-	12.6	18.9	Not susceptible
Cold leg	Centrifugal	-	17.8	14.3	Not susceptible
Crossover leg	Centrifugal	-	14.0	18.6	Not susceptible
90° Elbow1	Static	13.0	12.9	12.7	Not susceptible
90° Elbow2	Static	15.6	16.6	15.4	Potentially susceptible
50° Bend	Static	17.4	14.6	14.3	Potentially susceptible
35° Bend1	Static	13.0	13.4	12.2	Not susceptible
35° Bend2	Static	16.0	17.0	16.2	Potentially susceptible

통 배관의 열취화 민감도 평가에 적용하였다. Table 5와 Table 6은 본 연구결과를 이용하여 CF-8M으로 제작된 국내 원전 1차계통 배관에 대하여 열취화 민감도 평가를 수행한 것이다. 배관의 재료시험성적서(CMTR, certified material test report)로부터 화학조성과 페라이트 함량 측정값을 확인하고 예측식과 인공신경망으로부터 구한 값을 비교하였으며, 2절에서 정리한 열취화 민감도 평가기준을 적용하여 열취화 민감도 평가를 수행하였다.

인공신경망 예측값은 전반적으로 재료시험성적서 상의 측정값과 일치하였으며, 측정값이 없는 원심주조 배관에서는 Aubrey 예측값보다 보수적으로 평가되었다. 또한 열취화 민감도 평가결과 일부 정적주조로 제작된 엘보우와 밴드에서 열취화에 민감한 것으로 평가된 바, 이들 부위에 대

한 파괴역학적인 건전성평가가 요구된다.

## 6. 결 론

본 연구에서는 인공신경망을 이용하여 주조 스테인리스강의 페라이트 함량 예측방법을 제시하고 그 효용성을 검증하였으며, 국내 원전 1차계통 배관에 적용하여 열취화 민감도를 평가하였다.

주조 스테인리스강의 측정데이터를 이용한 인공신경망 학습 결과 목표값과 출력값이 잘 일치하였으며, 해외 원전의 측정데이터로 검증한 결과 인공신경망을 이용한 페라이트 함량 예측은 효과적인 방법으로 검증되었다. 또한 CF-8M으로 제작된 국내 원전 1차계통 배관의 열취화 민감도 평가에 본 연구에서의 방법을 적용한 결과 일부 정적주조로 제작된 엘보우와 밴드에서 열취화에 민감한 것으로 평가된 바, 이들 부위에 대한 파괴역학적인 건전성평가가 요구된다.

본 연구에서 제시한 방법은 신경망 학습을 위한 측정데이터를 추가하여 보다 정확한 예측이 가능할 것이며 향후 충격에너지, 인장특성 등 재료물성치의 예측으로 확장할 수 있을 것이다.

## 후 기

본 연구는 과학기술부 중장기 과제인 '원전 주기적안전성평가기술 개발'의 일부로 수행중인 '경년열화 손상관리 적용기술 개발'과 관련하여 한국전력기술(주)과 전력연구원의 공동연구에 의해 이루어졌으며 이에 관계자 여러분들께 감사드립니다.

## 참고문헌

- (1) Shah, V. N. and Macdonald, P. E., 1993, "Aging and Life Extension of Major Light Water Reactor Components," ELSEVIER, pp. 146~186.
- (2) Lietzan, L. M., Mathew, M. D., Murty, K. L., and Shah, V. N., 1999, "Low Temperature Aging Embrittlement of CF-8 Stainless Steel," TMS, pp. 1~10.
- (3) Aubrey, L. S., Weiser, P. F., Pollard, W. J. and Schoefer, E. A., 1982, "Ferrite Measurement and Control in Cast Duplex Stainless Steels," ASTM STP 756, pp. 126~164.
- (4) ASTM, 2001, "Standard Practice for Steel Casting, Austenitic Alloy, Estimating Ferrite Content Thereof" ASTM A800/A 800M-01.
- (5) USNRC, 1994, "Estimation of Fracture Toughness of CASS during Thermal Aging in LWR Systems," NUREG/CR-4513, Rev. 1.
- (6) USNRC, 2001, "Generic Aging Lessons Learned(GALL) Report," NUREG-1801 Vol. 2, pp. ? M-44~46.
- (7) Fausett, L., 1994, *Fundamentals of Neural Network : Architectures, Algorithms and Applications*, Prentice Hall, pp. 3~37.
- (8) Rumelhart, D. E., Hinton, G. E. and Williams, R. J., 1986, "Learning Internal Representations by Error Propagation : in *Parallel Distributed Processing*," The MIT Press, Vol. 1, pp. 675~695.
- (9) USNRC, 1994, "Mechanical Properties of Thermally Aged Cast Stainless Steels from Shippingport Reactor Components," NUREG/CR-6275, ANL-94/37.