

신경망을 이용한 원자력발전소의 주요 고장진단

권순일, 이종규, 송치권*, 배현*, 김성신*
 한국수력원자력(주) 원자력교육원, 부산대학교 전기공학과*

The Fault Diagnosis using Neural Networks for Nuclear Power Plants

Kwon Soon-il, Lee Jong-kyu, Song Chi-kwon*, Bae Hyeon*, Sungshin Kim*
 Korea Hydro & Nuclear Power Co., Ltd. Dept. of Electrical Eng., Pusan National University*

Abstract - Nuclear power generations have been developed gradually since 1950. Nowadays, 440 nuclear power generations are taking charge of 16% of electric power production in the world. The most important factor to operate the nuclear power generations is safety. It is not easy way to control nuclear power generations with safety because nuclear power generations are very complicated systems. In the main control room of the nuclear power generations, about 4000 numbers of alarms and monitoring devices are equipped to handle the signals corresponding to operating equipments. Thus, operators have to deal with massive information and to grasp the situation immediately. If they could not achieve these task, then they should make big problem in the power generations. Owing to too many variables, operators could be also in the uncontrolled situation. So in this paper, automatic systems to diagnose the fault are constructed using 2 steps neural networks. This diagnosis method is based on the pattern of the principal variables which could represent the type and severity of faults.




그림 1. 원자력 발전소의 주요 계통도

1. 서 론

원자력 발전은 1950년대 중반에 도입된 후 성장하여, 현재는 전세계적으로 440여기가 전체생산의 16%를 담당하지만, 핵분열 과정에서 발생하는 방사성 물질로 인하여 논란이 크고 안전성에 대한 우려는 환경 파괴를 우려하는 최근의 경향과 맞물려 원자력 산업의 성장을 둔화시키는 가장 큰 원인이다 [1].

원자력발전소는 안전성을 최우선으로 하는 복잡한 대규모 시스템으로써 주제어실에는 4000여 개의 경보 및 감시장치들이 설치되어 있다. 발전소 운전원은 방대한 양의 정보들을 처리하면서 발전소를 제어하여 최적정격 출력운전을 한다. 그러나 발전소가 과도현상, 운전 정지, 또는 비정상상태로 되면 사건 초기에 약 500여 개 이상의 경보가 발생되고, 많은 운전변수들이 동시에 변하여 운전원에게 부담을 준다 [2]. 1979년 미국에서 발생한 TMI(Three Mile Island) 원전 사고에서는 사고 원인이 운전원에게 요구되는 각종 경보 및 감시계기 등을 통한 너무 많은 정보들로 인하여 오히려 운전원의 적절한 대응조치를 취하는데 혼란을 가중시켰다고 보고되었다 [3]. 본 논문에서는 이러한 많은 정보들을 이용하여 자동화된 사고진단 방법을 찾고, 주어진 데이터의 패턴을 신경망을 이용하여 분류한 효과적인 사고진단을 한다.

2. 본 론

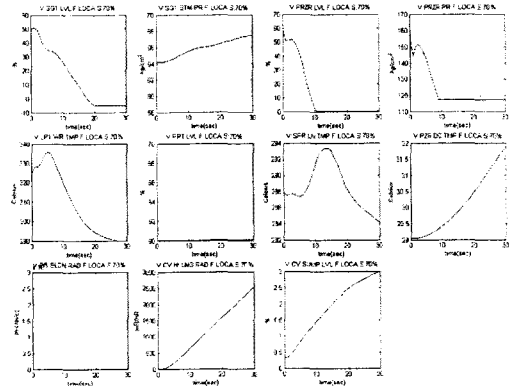


그림 2. LOCA 70%에 대한 11개 변수 패턴

2.1 연구배경

2.1.1 원자력발전소의 고장진단

원자력발전소에서는 다양한 사고들이 발생할 수 있지만, 주요한 기능을 하는 장치들이 고장이 났을 경우 파생적으로 큰 사고로 발전할 우려가 있다. 그림 1에 원자력 발전소의 계통도를 나타내었다. 이러한 격납용기 내부의 장치들은 방사성 물질과 연관이 있어 조심스런 사고 판리가 요구된다.

본 논문에서는 운전원의 오판으로 대응조치가 잘못 되었을 때 주변환경을 방사성물질로 오염시킬 가능성이 있는 사고 위주로 사고분류를 하였다. 6가지의 주요한 사고에 대해 나타나는 11개 주요 변수들의 데이터를 얻어 고장진단을 한다 [4]. 사고명은 다음과 같다.

- ① 증기발생기 튜브파열사고(SGTR)
- ② 원자로냉각재 상실사고(LOCA)

- ③ 가압기 살수밸브 개방고착사고(PZR SPRAY)
- ④ 가압기 안전밸브 개방고착사고(PZR PSV)
- ⑤ 주증기관 파단사고(MSLB)
- ⑥ 주급수관 파단사고(MFLB)

그림 2에는 사고크기 70%의 LOCA사고에 대한 11 가지 변수들의 패턴을 왼쪽에서 오른쪽으로 차례대로 나타내었다. 입력변수는 다음과 같다.

- ① 증기발생기 수위(SG1L)
- ② 증기발생기 압력(SG1SP)
- ③ 가압기 수위(PZRL)
- ④ 가압기 압력(PZRP)
- ⑤ 광역 고온관 온도(LP1WT)
- ⑥ 가압기 압력 방출탱크 수위(PRTL)
- ⑦ 가압기 살수밸브 후단온도(SLDT)
- ⑧ 가압기 안전밸브 후단온도(PSLT)
- ⑨ 증기발생기 취출수 방사능(SGBR)
- ⑩ 격납용기 광역 방사능(CVHR)
- ⑪ 격납용기 배수조 수위(CVSL)

2.1.2 시뮬레이터

본 실험에서 사용한 실험 데이터들은 실제 가동 중인 원자력발전소를 모방한 시뮬레이터를 통해서 획득한 것들이다. 실제 사고가 발생하였을 때와 같은 조건하에 만들어진 데이터이므로 신뢰도가 높다. 본 실험에서 사용한 고장 데이터는 Full-Scope 시뮬레이터에서 획득하여 실제발전소의 고장에도 거의 같은 값을 얻게 되므로, 실제 현장에서도 사용 가능하다고 할 수 있다.

2.1.3 신경망 구조

본 논문에서 사용한 신경망은 그림 3과 같이 두 개의 독립된 신경망을 직렬형으로 연결하였다. 분류목적이 사고의 종류와 크기이기 때문에 하나의 학습을 마치고 나온 결과를 기반으로 하여 두 번째 결과를 테스트하는 것이 보다 효과적이라고 생각한다.

모의실험에 사용한 신경망의 1차 네트워크에서 먼저 사고의 종류를 분류한다. 첫 번째 학습은 사고크기는 고려하지 않고 사고의 종류에 대해서만 이루어진다. 이렇게 학습된 신경망을 이용하여 임의의 사고 데이터를 이용하여 모의 실험을 수행한다 [5]. 사고 분류가 끝나고 나면 출력값을 통해 실험한 데이터가 어떤 사고의 정보를 가지고 있는지 알 수 있다. 분류된 정보를 가지고 다

시 2차 네트워크를 이용하여 실험한다. 여기서 2차 네트워크는 이미 각 사고에 대해 사고종류만 고려하여 학습을 마친 상태이다. 1차 네트워크의 입력으로 사용한 데이터를 다시 2차 네트워크의 입력으로 넣으면 출력단에서 사고의 크기를 분류할 수 있다. 최종적으로 두 결과를 조합함으로써 테스트 데이터가 어떤 종류의 사고이고, 그 사고의 고장크기가 얼마나 되는지 알 수 있다. 신경망 학습은 신뢰할 만한 도구인 MATRAB[®]을 사용하였다 [6].

2.2 모의 실험

2.2.1 1차 네트워크에 의한 사고종류 진단

① hyperbolic tangent(은닉층, 출력층) 함수 사용:
1차 네트워크의 은닉층과 출력층 활성화함수를 모두 hyperbolic tangent 함수를 써서 모델을 구성하였다. 실험결과와 오차는 다소 컸으나, 사고 분류는 가능함을 알 수 있었다.

② logistic, hyperbolic tangent 사용:
앞의 모의실험에서 본 결과와 비교할 때 성능이 훨씬 나빠진 것을 볼 수 있다. 특히 사고크기가 큰 경우에 있어서 테스트 오차가 큼을 알 수 있다. hyperbolic tangent 함수의 특성에 의해 사고크기가 클 경우 알맞은 값으로 활성화되지 못한다. 오차가 크지만 역시 사고 종류 구별은 가능하다.

③ hyperbolic tangent, logistic 사용:
표 1.의 결과에 이 경우를 나타내었다. 세 개의 활성화 함수 조합 중 가장 좋은 성능을 보인다. 특히 사고 크기가 클 경우에도 결과값들이 좋게 나오는 것을 알 수 있다. 따라서 2차 네트워크에서 사고크기 분류를 할 경우에도 본 실험에서 사용한 활성화 함수 조합을 적용한다.

본 모의실험의 결과를 통해 전체적으로 사고분류가 잘 됨을 알 수 있다. 단지 사고의 패턴이 비슷하거나 사고 시 변수들의 변화가 경미한 경우는 오차의 크기가 큰 것을 확인할 수 있었다. 그러나 다소 성능의 차이는 있지만 1차 네트워크가 사고종류를 구분하기 위해 사용되기 때문에 오차에 대한 평가보다는 성능을 고려하는 것이 알맞을 것이다. 이러한 관점에서 볼 때 작은 크기의 오차는 허용될 수 있다. 특히 결과값이 목표값 근처로 수렴해 가기 때문에 신경망의 학습이 적절하게 잘된다고 할 수 있다.

2.2.2 2차 네트워크에 의한 사고크기 진단

2차 네트워크는 1차 네트워크에서 이미 분류된 사고에 대한 크기분류를 위하여 사용한다. 분류할 사고 크기는 40%, 50%, 60%, 70%, 80%의 5가지이다. 각 사고에 대하여 학습을 하므로 2차 네트워크의 신경망 모델은 6개이다. 6개의 신경망 모델의 구조는 크기분류를 위한 구조와 동일하다. 활성화함수는 앞 절의 실험에서 사용한 은닉층에는 hyperbolic tangent 함수를 사용하고 출력층에는 logistic 함수를 사용한다. 두 활성화함수의 조합은 사고종류를 분류하기 위한 실험에서 성능이 우수하다고 확인되었기 때문에 본 신경망 모델에도 적용하였다. 학습을 위한 출력층의 목표값은 1로 설정하여 학습동안 출력값이 수렴하도록 하였다.

2.2.3 학습되지 않은 데이터의 사고진단

본 절에서의 모의실험은 학습되지 않은 사고 종류에 대해서 진단이 가능한지를 알아보기 위한 테스트이다. 예를 들어 40%, 60%, 80%의 사고크기를 이용하여 신경망 모델을 학습한 후 50%와 70%의 테스트 데이터를 입력했을 때 사고종류를 정확하게 분류되는지를 실험하였다. 이와 같은 모의실험을 위한 기본 배경은 신경망이 가진 적응성에 기초한다. 다시 말해 신경망의 특성상 유사한 패턴을 가진 신호에 대해서 선별할 수 있는 능력을 가지고 있기 때문이다.

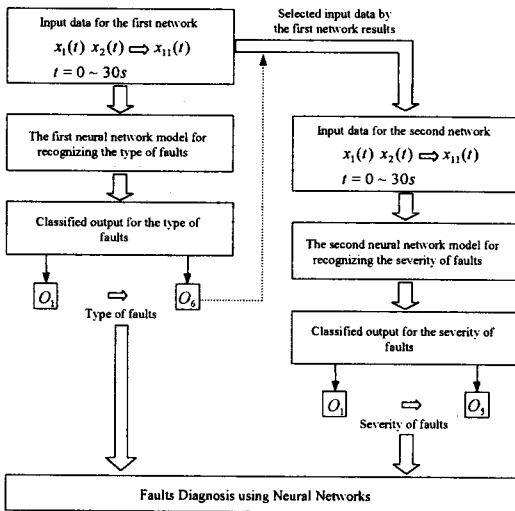


그림 3. 사고진단을 위한 2단 신경망 구성도

2.2.4 실험결과

표1. 1차 네트워크에 의한 사고종류 진단

종류	크기 (%)	목표	테스트결과 (30초 동안의 평균값)					
			Y1	Y2	Y3	Y4	Y5	Y6
SGTR	40	0.6	0.5651	0.0002	0.1259	0.0427	0.0092	0.0295
	50	0.7	0.6748	0.0002	0.0608	0.0233	0.0379	0.0211
	60	0.8	0.7555	0.0004	0.0481	0.0197	0.0859	0.0171
	70	0.9	0.7195	0.0011	0.0559	0.0131	0.1462	0.0266
	80	1.0	0.8473	0.0001	0.0251	0.0663	0.0522	0.2338
LOCA	50	0.7	0.0052	0.7349	0.0002	0.0812	0.0575	0.0425
	60	0.8	0.0026	0.7720	0.0001	0.0867	0.0670	0.0380
	70	0.9	0.0103	0.7749	0.0000	0.1072	0.0776	0.0313
PZR	80	1.0	0.0032	0.8154	0.0000	0.1006	0.0928	0.1255
	40	0.6	0.0199	0.0001	0.7731	0.0022	0.0816	0.0903
SPRAY	50	0.7	0.0339	0.0001	0.7034	0.0023	0.0698	0.1171
	60	0.8	0.0339	0.0001	0.7034	0.0023	0.0698	0.1255
PZR	80	1.0	0.0949	0.0000	0.7377	0.0054	0.0046	0.0861
	50	0.7	0.0279	0.0749	0.0008	0.7319	0.0092	0.0431
PSV	60	0.8	0.0250	0.0901	0.00064	0.7390	0.0100	0.0364
	70	0.9	0.0169	0.0996	0.0006	0.7589	0.0105	0.0344
MSLB	80	1.0	0.0156	0.0840	0.0005	0.7968	0.0088	0.0377
	40	0.6	0.0653	0.0106	0.0369	0.0027	0.5671	0.0435
MFLB	50	0.7	0.0744	0.0173	0.0296	0.0109	0.4914	0.0417
	60	0.8	0.0640	0.0170	0.0970	0.0106	0.0119	0.5198
MFLB	70	0.9	0.0622	0.0166	0.0782	0.0098	0.0280	0.5949
	80	1.0	0.0085	0.0349	0.0937	0.0389	0.0236	0.7616

표2. 2차 네트워크에 의한 사고크기 진단

종류	크기 (%)	목표	테스트결과(30초 동안의 평균값)				
			Y1	Y2	Y3	Y4	Y5
SGTR	40	1.0	0.8636	0.1510	0.0176	0.0000	0.0081
	50	1.0	0.1052	0.6196	0.3358	0.1016	0.0019
	60	1.0	0.0586	0.2787	0.3909	0.1361	0.0038
	70	1.0	0.0346	0.0552	0.2712	0.7864	0.0225
	80	1.0	0.0318	0.0000	0.0001	0.0061	0.9794
LOCA	40	1.0	0.7368	0.3045	0.1366	0.0566	0.0241
	70	1.0	0.0350	0.1039	0.2374	0.3884	0.2358
	80	1.0	0.0225	0.0866	0.1714	0.3343	0.7100
PZR	40	1.0	0.8163	0.2679	0.0280	0.0085	0.0208
	60	1.0	0.0065	0.2325	0.4798	0.3399	0.0164
	70	1.0	0.0586	0.2280	0.3509	0.4642	0.3509
	80	1.0	0.0433	0.0189	0.0114	0.0269	0.9282
PSV	40	1.0	0.5904	0.2425	0.1074	0.0785	0.0689
	50	1.0	0.1684	0.4068	0.2264	0.0845	0.0718
	60	1.0	0.0876	0.2113	0.4497	0.2402	0.0439
MSLB	80	1.0	0.0732	0.0743	0.0657	0.0657	0.7191
	40	1.0	0.5935	0.2708	0.2117	0.0906	0.0020
MFLB	80	1.0	0.0563	0.0912	0.1281	0.3135	0.6619
	70	1.0	0.0908	0.0573	0.3720	0.6197	0.0091
MFLB	80	1.0	0.0329	0.2035	0.0411	0.0085	0.9229

표 3. 학습되지 않은 데이터에 대한 실험결과

종류	크기 (%)	목표	테스트결과 (30초 동안의 평균값)					
			Y1	Y2	Y3	Y4	Y5	Y6
SGTR	50	0.7	0.5818	0.0000	0.1024	0.0029	0.0333	0.0406
	70	0.9	0.4454	0.0005	0.0920	0.0038	0.1770	0.0963
LOCA	50	0.7	0.0011	0.7642	0.0294	0.0572	0.0872	0.0229
	70	0.9	0.0014	0.7726	0.0249	0.1045	0.0711	0.0270
PZR	50	0.7	0.0010	0.0404	0.0129	0.7616	0.0337	0.0187
PSV	70	0.9	0.0007	0.0615	0.0106	0.7811	0.0132	0.0042
MSLB	50	0.7	0.0459	0.0143	0.0667	0.0139	0.6544	0.0803
	70	0.9	0.0201	0.0584	0.0238	0.0249	0.5914	0.0606
MFLB	50	0.7	0.1581	0.0156	0.0263	0.0006	0.0253	0.5773
	70	0.9	0.0738	0.0181	0.0168	0.0006	0.0474	0.6255

각각의 실험에 대한 결과를 표에 나타내었다. 표1은 1차 네트워크에서 사고 종류를 구별하는 결과를 나타내었고, 분류된 사고 종류에 대해 크기를 분류하는 2차 네트워크에 대한 결과이다. 표3은 학습되지 않은 데이터에 대해 사고 종류를 분류하는 실험결과를 나타내었다.

3. 결 론

본 논문에서는 실제 운전중인 원자력발전소를 모방한 시뮬레이터로부터 획득한 데이터를 신경망을 이용한 패턴 인식방법을 이용하였다. 각 사고에 대한 변수는 총 11개를 사용하였고 사고의 종류는 6개이다. 11개의 변수는 사고가 발생했을 때 계기들의 값의 변화로서 0초에서 30초까지의 경과를 기준으로 하였다. 본 논문에서 구성한 신경망 모델을 이용하여 학습한 후 테스트를 해본 결과 각 사고의 종류를 효율적으로 분류할 수 있음을 알 수 있었다. 물론 패턴이 비슷한 사고의 경우 다른 경우보다 오차가 많이 발생하였다. 변수의 변화가 경미한 경우에는 신경망으로 분류하는 것이 쉽지 않음을 알 수 있었다. 따라서 유사한 패턴을 가진 사고를 분류하기 위해서는 보조적인 방법이 함께 고려되어야 할 것이다.

본 논문에서는 2가지의 사고진단 방법에 대하여 실험하였다. 먼저 단일 사고에 대한 데이터를 이용하여 신경망을 학습하고 테스트를 통해 사고진단이 가능한지 검토해 보았으며 두 번째로 신경망의 적응성을 이용하여 학습되지 않은 사고에 대해서도 진단이 가능한지 모의실험하였다. 두 경우에 있어서 사고진단이 잘되는 것을 확인되었다. 단일 사고에 대해서는 사고크기도 함께 고려하여 실험하였는데 총 사고크기는 40%~80%까지 5개로 나누어서 실험하였고 분류가 잘됨을 확인할 수 있었다. 두 진단의 경우 hyperbolic tangent함수를 은닉층, logistic함수를 출력층 활성화함수로 사용하였을 경우에 있어서 성능이 우수하였다. 따라서 활성화함수의 선택이 신경망의 학습에 중요함을 알 수 있다.

전반적으로 본 모의실험을 통해 다양한 사고종류와 크기를 가진 데이터를 통해 원하는 진단결과로 신경망을 학습시킬 수 있고 원하는 진단결과를 얻을 수 있음을 확인할 수 있었다. 그리고 이러한 결과를 바탕으로 하여 알고리즘을 보완할 수 있다면 실제 현장에서 과도상태 또는 비상상태 발생시 운전원이 하는 사고진단들을 지능 제어 기법을 이용하여 대항할 수 있다고 생각된다.

[참 고 문 헌]

- [1] 장순홍, 백원필, 원자력안전(Nuclear Safety), 청문각, pp 1-37, 1998
- [2] R. E. Uhrig, "Potential application of neural networks to the operation of nuclear power plant," Nuclear Safety, vol.32, No.1, pp. 68-78, 1991.
- [3] 장순홍, 전문현외, "원자력발전소 고장진단 및 비상조치 지원시스템 구축을 위한 연구," Technical Report, 한국전력공사 기술연구원, 1994.
- [4] "PWR Accident Analysis and Mitigating Core Damage," Technical report, Westinghouse Training and Operational Services, 1991.
- [5] S. W. Chang, S. H. Chang, and H. Y. Chung, "Application of neural networks to multiple alarm processing and diagnosis in nuclear power plant," Processing of the Korean Nuclear Society Spring Meeting, Kori, Korea, May 1992.
- [6] H. Demuth, M. Beale, "Neural Network Toolbox for Use with MATLAB," The MATHWORKS Inc.