

신경회로망을 이용한 송전선 허용용량 예측기법

(Dynamic Line Rating Prediction in Overhead Transmission Lines Using Artificial Neural Network)

노신의* · 김이관 · 임성훈 · 김일동**

(Shin-Eui Noh · Yi-Gwhan Kim · Sung-Hun Lim · Il-Dong Kim)

Abstract

With the increase of demand for electricity power, new construction and expansion of transmission lines for transport have been required. However, it has been difficult to be realized by such opposition from environmental groups and residents. Therefore, the development of techniques for effective use of existing transmission lines is more needed. In this paper, the major variables to affect the allowable transmission capacity in an overhead transmission lines were selected and the dynamic line rating (DLR) method using artificial neural networks reflecting unique environment-heat properties was proposed. To prove the proposed method, the analyzed results using the artificial neural network were compared with the ones obtained from the existing method. The analyzed results using the proposed method showed an error of 0.9% within \pm , which was to be practicable.

Key Words : Overhead Transmission Line, Allowable Transmission Capacity, Dynamic Line Rating(DLR), Artificial Neural Network

1. 서 론

최근 급격한 전력수요의 증가로 인해 국내 전력계통

의 송전능력의 확대가 필요하고 있으나. 건설 지역의 민원으로 인해 송전선로의 건설은 갈수록 어려워지고 있다. 이에 따라 기존의 송전선로들을 통하여 가능한 최대한의 전력을 송전할 수 있는 노력이 더욱 필요해지고 있다. 대부분의 전력회사들은 가공송전선의 허용전류를 최악의 기상조건에서 가용용량을 산출하는 정적 송전용량(Static Line Rating : SLR)을 적용해서 운용하고 있다. 그러나, 이와 같은 기상조건은 발생할 확률이 드물어서 실제 선로는 허용용량에 여유를 가지고 운용된다. 이에 따라 현재 선로에 더 많은 전력을 공급하기 위해 기상상태를 실시간으로 모니터링하여 용량을 산정하는 동적 송전용량 산정(Dynamic

* 주저자 : 송실대학교 전기공학부 석사과정
** 교신저자 : 두원공과대학 교수
* Main author : Master Course Student, Dept. of Electrical Engineering, Soongsil University
** Corresponding author : Professor, Doowon Technical University College
Tel : 031-8056-7168, Fax : 031-8056-7161
E-mail : idkim@doowon.ac.kr
접수일자 : 2013년 10월 24일
1차심사 : 2013년 10월 25일
심사완료 : 2013년 11월 23일

Line Rating : DLR)이 주목되고 있다. 그러나 동적 송전 용량 산정을 이용하기 위해서는 도체 주변의 여러 가지 기상변수, 지리적인 위치 및 도체의 상태 등 수많은 데이터들을 고려해야 하므로 실용화하기 어려운 점이 있다[1-3].

본 논문에서는 이와 같은 문제점들을 해결하기 위해 열평형 방정식에 영향을 주는 다수의 변수들 중 영향력이 큰 변수들을 연구 도출하고 이 변수들을 입력변수(패턴)로 하는 인공 신경회로망을 학습시켜 실제 송전선이 가지는 환경과 열특성을 학습하게 하여 허용 송전용량 예측이 필요한 변수들을 제시함으로써 허용 송전용량을 예측하는 실용적 기법을 제시하였다.

2. 본 론

2.1 기존의 가용용량예측기법

송전선로의 가용용량을 산출하는 방법으로는 최악의 기상조건에서 가용용량을 산출하는 정적송전용량(Static Line Rating : SLR)과 기상상태를 실시간으로 모니터링하여 용량을 산정하는 동적 송전용량 산정(Dynamic Line Rating : DLR) 방법이 있다. 이 두 가지 방식 모두 열평형 방정식을 사용하는데 그 수학적 모델링은 다음 식 (1) 및 식 (2)~(4)와 같이 표현된다[4].

$$Q_c + Q_r = Q_s + I^2 R_{ac}(T_c) \times 10^{-3} \quad (1)$$

$$Q_c = f(K_\phi, D, H_e, V_w, \mu_f, K_f, T_c, T_a) [W/m] \quad (2)$$

$$Q_r = f(D, \epsilon, T_c, T_a) [W/m] \quad (3)$$

$$Q_s = f(\alpha, q_s, L_{at}, \delta, Z_c, Z_L, \omega, A') [W/m] \quad (4)$$

여기서

Q_c : 대류에 의한 열방산

Q_r : 방사에 의한 열방산

Q_s : 일사에 의한 흡수열

$R_{ac}(T_c)$: 온도 T_c °C에서의 교류저항 Ω/km

K_ϕ : 풍향 각 보정계수(풍향각 고려시 적용)

D : 도체의 외경 mm 및 강심의 외경 mm

H_e : 해발고도 m

V_w : 풍속 m/sec

μ_f : 공기의 점도 $N/m \cdot s$

K_f : T_{film} °C에서 공기의 열전도율 $W/m \cdot ^\circ C$

T_c : 도체의 온도 °C

T_a : 주위 공기온도 °C

ϵ : 방사계수 : 0.23~0.91

α : 태양열 흡수계수 : 0.23~0.91

q_s : 일사량 W/m^2

L_{at} : 위도 °N

δ : 태양의 경사각(0~90)

Z_c : 태양의 방위각 °

Z_L : 선로의 방위각(남북선로 : 0°, 동서선로 : 90°)

ω : 태양이 가장 높은 시각의 정오에 대한 시간각도 °
(AM 11:00 -15°, PM 2:00 30°)

A' : 도체의 투영면적 m^2/m

이 방정식을 송전용량(I)을 산정하기 위해 다시 정리하면 식 (5)와 같다.

$$I = \sqrt{\frac{Q_c + Q_r - Q_s}{R_{ac}(T_c) \times 10^{-3}}} \quad (5)$$

그러나 위의 수식들을 통하여 허용용량을 산출하기 위해서는 무려 18개에 달하는 다양한 환경 물리적 변수들을 알아야 하고, 그 중에는 넓은 범위에 위치한 송전선로에 일률적으로 적용하기 어려운 변수들(예 : 공기 점도, 태양 경사각, 방위각 등)도 있어 실용적이지 못함을 알 수 있다.

2.2 영향력이 큰 주요 변수 분석

서론에서 언급한바와 같이 보다 실용적인 예측을 가능하게 하기 위하여 앞의 수식으로 표현된 허용용량 산출식에서 영향력이 작은 변수들을 배제시키고자 반대로 영향력이 큰 변수들을 분석 검토하였다. 검토에서 사용된 도체전선은 ACSR(Aluminum Conductor Steel Reinforced) 410mm²을 사용하였고, 허용용량산

출식에 각 변수들의 변화량에 따른 허용전류 결과값의 검토를 통해 허용송전용량에 영향력이 큰 상위 6가지 변수들을 표 1에 나타내었다.

상기 6가지 변수 중 맨 아래 해발고도는 사실상 다른 5개 변수보다 영향력이 크게 낮음을 알 수 있으며 따라서 실용화를 용이하게 하기 위하여 이 변수는 비중요변수로 분류하였다.

표 1. 영향력이 큰 변수들
Table 1. The most influential variables

변수명	변화범위	허용전류 변화 A	변화폭	그래프
도체온도	50~90℃	80~850	19.3A/℃	그림 1
기온	-20~10℃	850~1300	15.3A/℃	그림 2
풍속	0~1m/sec	280~1000	720A/(m/sec)	그림 3
풍향각	0~50°	570~1020	9A/°	그림 4
흡수열	0~14.953W/m	860~840	1.338A	그림 5
해발고도	0~1000	836~860	0.024A/m	

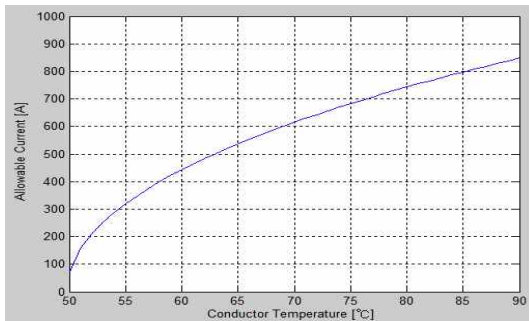


그림 1. 도체온도 변동에 따른 허용전류 변화
Fig. 1. Variation of the conductor temperature




그림 2. 기온 변동에 따른 허용전류 변화
Fig. 2. Variation of the atmosphere temperature

그림 1은 도체온도 변동에 따른 허용전류 변화를 나타낸 것으로 ACSR 410mm² 전선 기준 최고허용온도인 90℃까지의 허용전류 변화를 나타냈다. 나타낸 그림은 도체의 온도가 높아질수록 더 많은 전류를 전송시킬 수 있음을 보여준다. 그림 2는 우리나라 40년간 최저온도 -20℃에서 최고 온도 40℃까지의 기온 변동에 대한 허용전류를 나타낸 그림이며, 기온이 높아질수록 허용전류는 작아짐을 확인할 수 있다.

그림 3은 전선주변의 대류에 의한 열방산에 관련된 변수 중 풍속이 허용송전용량에 미치는 영향을 보인 것이다. 풍속 0~1m/sec까지 변함에 따른 허용전류 변화를 나타낸 것으로 바람이 전혀 없을 때는 약 280A이나 초속 1m 풍속이면 그 냉각효과로 약 1,000A까지 송전할 수 있음을 보인 것이다.



그림 3. 풍속 변동에 따른 허용전류 변화
Fig. 3. Variation of the wind velocity




그림 4. 풍향각 변동에 따른 허용전류 변화
Fig. 4. Variation of the wind angle

그림 4는 풍향각 변동에 따른 허용용량 변화를 나타낸 것으로 도체와 풍향 사이의 각도가 50° 부근에서 최대 허용전류가 나타나고, 도체의 방향과 바람의 방

향이 같은 경우는 열의 대류 효과가 가장 낮게 나타나며 도체에 대하여 직각을 이루는 바람은 영향력이 다소 저하됨을 알 수 있다.

그림 5는 일사량 변동에 따른 허용전류 변화를 나타낸 그림이며, 일사량이 높을수록 도체가 태양으로부터 흡수하는 열이 많아져 허용전류가 감소한다. 그림에서 나타난 허용전류는 ACSR 410mm² 전선 기준으로 계산식에서의 최대 흡수열까지인 14.953W/m까지의 허용전류 변화를 나타내었다.




그림 5. 일사량 변동에 따른 허용전류 변화
Fig. 5. Variation of the Quantity of Solar radiation

2.3 인공 신경회로망을 적용한 예측기법

2.3.1 신경회로망의 원리와 특징

인공 신경회로망(Artificial Neural Network)은 매우 오래전에 제안되었으나 최근에 컴퓨터 기술 및 마이크로전자 기술의 발달과 더불어 활발한 개발과 적용이 이루어지고 있는 기술이다. 신경회로망의 중요한 특징은 학습할 수 있는 기능이며 특히, 지식이 규칙적인 형태를 가지고 명확하게 표현되는 규칙만을 기반으로 하는 전문가시스템(Rule-based Expert System)과는 달리 불규칙한 형태의 정보에 대하여도 그 불규칙성을 학습시켜 다룰 수 있다. 즉 불규칙한 형태로 주어지는 여러 가지 표본을 통하여 “학습”함으로써 이에 적절한 “출력”(결과)을 낼 수 있는 회로망 연결강도(W)를 가지게 되므로 다른 불규칙한 조건이 주어 질 때에도 이에 적절한 결과를 산출해 낼 수 있게 된다. 일례로서 연세가 많으신 어르신들이 자연환경 변화나 현상을 보고 앞날의 일기도 예측해내는 것

은 오랜 동안의 학습(경험)을 통하여 두뇌에 저장된 생체 신경망의 연결 강도에 의하여 적절한 결과를 추론하는 것과 같다. 따라서 신경회로망은 명확한 규칙이 없는 현상들에 대하여 학습할 수 있는 능력을 가지고 있기 때문에 규칙을 알 수 없거나, 규칙이 복잡해서 명확히 정의하기 힘든 패턴인식 또는 비선형함수의 근사화 등과 같은 문제에 대하여 매우 적절히 응용될 수 있다[5-6].

본 연구에서는 이러한 신경회로망을 이용하여 각기 다른 환경에 놓여 있는 송전선 나뭇대로의 열 특성을 실제로 주어지는 주요변수들과 이때 나타나는 송전선의 온도를 통하여 학습하도록 하고 새롭게 주어지는 조건에서의 허용 용량을 예측하고자 하였다.

2.3.2 허용용량예측에서의 적용

송전선 허용용량은 앞 절에서 소개한 바와 같이 수식으로 산출할 수 있는 것으로 되어있으나 사실상 송전선 마다 통과지역이 다르고 각기 고유한 환경에 놓일 수 있으며 또 선로 구간마다 조건들이 다를 수 있어 수식에서 고려할 수 없는 영향들도 있게 된다. 따라서 본 연구에서는 실제로 해당 송전선에 나타나는 주요변수들과 당시의 도체온도들의 변화를 다양하게 측정하여 신경회로망 기법으로 해당 송전선의 열 특성을 학습하게 하여 새로이 주어지는 미래의 조건(변수들로 주어짐)에 대한 허용송전용량을 예측하게 하는 방법을 시도하였다.

학습에 적용한 변수들로는 앞에서 검토한 가장 영향력이 큰 상위 5가지 변수들 즉, 도체온도 °C, 대기 기온 °C, 풍속 m/sec, 도체와 풍향 사이의 각도 °, 태양 일사량 및 당시 실제 전류 A를 적용하였으며 학습과정은 그림 6과 같다.

2.3.3 신경회로망 학습과 허용용량예측

위에서 언급한 기법을 실현하기 위해서는 실제 송전선에 해당 변수들 취득을 위한 센서들을 설치하고 적어도 4계절이 지나는 기간 즉, 1년 이상의 장기간 중 대표적인 표본 데이터를 취득하여 신경회로망에 학습을 시켜야 하나 연구단계에서는 그렇게 하기에는 시간과 비용이 많아져 곤란하다. 따라서 본 연구에서는

앞에서 기술한 수식을 이용한 방법을 모델로 하여 주어진 조건에서 나타나는 전선온도를 역으로 계산한 것을 이용하여 학습을 시킨 후 학습 표본에는 없는 다른 조건들을 제시하고 그 때의 허용송전용량을 예측하여 그 결과를 비교하여 신경회로망 기법의 타당성을 입증하고자 하였다.

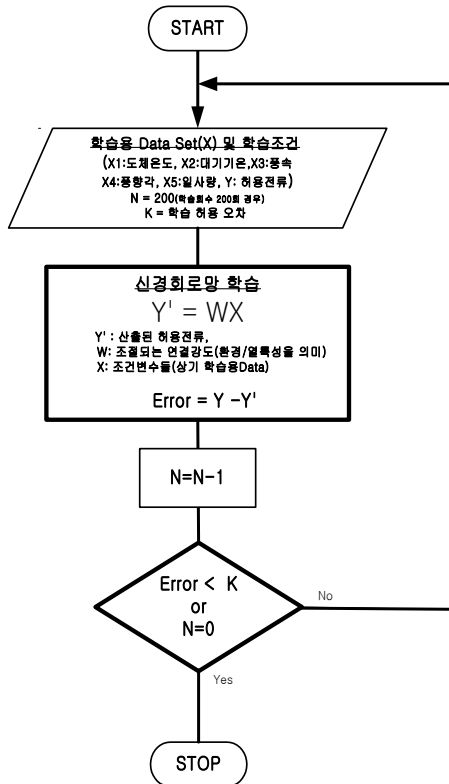


그림 6. 신경회로망 학습과정
Fig. 6. Flow chart for ANN training

1) 학습용 표본과 학습

1년 4계절의 일기 조건 중에서 계절별로 봄과 가을에서 5개, 여름에서 5개, 겨울에서 5개를 선택하고 이에 해당하는 도체온도를 예측하여 학습시켰다. 모델로 적용한 송전선 도체 온도는 역시 ACSR 410mm²이며 열특성은 앞의 식 (1)~(5)를 적용하였다.

표 2는 이들로부터 산출된 데이터이며, 이를 주요 5가지 변수 별로 각각의 분포를 보인 것이 그림 7, 8, 9, 10, 11이다. 적용된 신경회로망은 입력층, 1개의 중간층, 출력층으로 노드 수는 각각 5개, 3개, 1개로 구성하

였다. 학습된 상태의 일례를 보면 표본번호 Sp-1의 허용전류 값을 예상해보았다. 실제로 흐른 전류는 1359.8A이나 신경회로망을 이용하여 100 회 학습을 반복한 경우에는 예측전류가 1,503A로 계산되었으며 이어서 반복횟수를 100회씩 증가시키에 따라 1,503A, 1,460A, 1,422A, 1,396A 등으로 오차가 감소하고 최종적으로 1,371A로 수렴함을 확인할 수 있었다.

표 2. 학습을 위한 변수별 데이터
Table 2. Variables-specific data for ANN training

표본 번호	계절	도체 온도	기온	풍향	풍속	태양 조사	허용 전류
Sp-1	봄,가을	45	2.5	30	2	0	1359.8
Sp-2	봄,가을	55	5	22.5	1.8	200	1312.2
Sp-3	봄,가을	55	10	90	2.5	550	1268.0
Sp-4	봄,가을	50	12	45	2.2	600	1355.0
Sp-5	봄,가을	45	3	22.5	1.5	0	1182.8
Sm-1	여름	55	12	22.5	2.2	0	1289.6
Sm-2	여름	60	15	22.5	1.8	160	1239.5
Sm-3	여름	60	22	90	3	650	1198.9
Sm-4	여름	65	20	45	3.5	350	1372.0
Sm-5	여름	65	19	67.5	2	0	1420.6
Wt-1	겨울	35	-7	22.5	3.5	0	1467.6
Wt-2	겨울	35	-4	22.5	3.8	180	1431.2
Wt-3	겨울	40	0	45	4	350	1661.1
Wt-4	겨울	35	-5	90	1.8	230	1155.9
Wt-5	겨울	30	-9	22.5	2	0	1247.5




그림 7. 신경회로망 학습을 위한 1년중 대표 도체온도
Fig. 7. Conductor temperature for ANN training

신경회로망을 이용한 송전선 허용용량 예측기법




그림 8. 신경회로망 학습을 위한 1년중 대표 온도
Fig. 8. Atmosphere temperature for ANN training




그림 10. 신경회로망 학습을 위한 1년중 대표 풍향각
Fig. 10. Wind angle for ANN training




그림 9. 신경회로망 학습을 위한 1년중 대표 풍속
Fig. 9. Wind velocity for ANN training




그림 11. 신경회로망 학습을 위한 1년중 대표 일사량
Fig. 11. Quantity of Solar radiation for ANN training

2) 시험용 표본

학습된 신경회로망 성능을 입증하기 위하여 기존 학습용 변수와는 차이가 있는 새로운 변수들을 사용하여 시험하였다. 표 3은 새로운 변수 조건들과 변수 조건들을 허용전류계산식을 이용해 계산한 수식전류이다.

표 3. 예측을 위한 변수 조건별 데이터
Table 3. Variables-specific data for ANN testing

표본 번호	계절	도체 온도	기온	풍향	풍속	태양 조사	수식 전류
Sp-1	봄, 가을	40	1	30	1.7	0	1263.7
Sp-2	봄, 가을	50	4	90	2.5	180	1317.0
Sp-3	봄, 가을	60	11	45	2.6	530	1592.6
Sp-4	봄, 가을	65	15	22.5	1.8	590	1209.0

Sp-5	봄, 가을	65	2	30	1.1	0	1127.2
Sm-1	여름	55	18	30	0.6	0	953.5
Sm-2	여름	65	27	45	2.2	300	1345.3
Sm-3	여름	65	32	22.5	3.2	680	1170.1
Sm-4	여름	55	22	22.5	3	450	1183.9
Sm-5	여름	55	20	45	1.2	0	1152.6
Wt-1	겨울	25	-10	45	3	0	1504.8
Wt-2	겨울	30	-4	67.5	1.9	150	1262.7
Wt-3	겨울	35	-4	67.5	1.5	220	1262.1
Wt-4	겨울	35	-8	30	1.3	320	1230.2
Wt-5	겨울	30	-12	22.5	1	0	1101.0

신경회로망 학습을 이용하여 새로운 변수 조건의 각 수식전류를 목표 값으로 설정하여 오차가 ± 0.9 % 이

내에 도달할 때 학습을 마침으로서 예측전류를 찾았다. 그에 대한 학습 반복 과정의 데이터는 표 4를 통해 정리하였다.

표 4. 학습 반복횟수 증가에 따른 예측전류 변화
Table 4. Variation of predictive current due to increase in the number of learning iterations

표본 번호	100회 반복 예측전류	200회 반복 예측전류	300회 반복 예측전류	400회 반복 예측전류	500회 반복 예측전류	600회 반복 예측전류	700회 반복 예측전류
Sp-1	1308	1291	1281	1274			
Sp-2	1364	1332	1318				
Sp-3	1646	1617	1604				
Sp-4	1276	1246	1231	1223	1219		
Sp-5	1212	1173	1152	1142	1138	1136	
Sm-1	995	974	963	956			
Sm-2	1399	1377	1362	1353			
Sm-3	1217	1193	1179				
Sm-4	1275	1245	1223	1209	1201	1196	1194
Sm-5	1228	1195	1176	1166	1161		
Wt-1	1546	1528	1516				
Wt-2	1353	1319	1296	1281	1274		
Wt-3	1291	1276	1269				
Wt-4	1249	1240					
Wt-5	1149	1131	1121	1116	1113	1111	1110

그림 12, 13, 14는 각각 표 4의 의 봄과 가을, 여름, 겨울 샘플의 수식전류와 예측전류간의 오차를 학습 반복 횟수 증가에 따른 오차율 변화로 나타낸 그림이다. 그림에서 나타낸 오차율은 학습 반복이 증가함에 따라 감소하고, 오차가 0.9% 이내에 도달했을 경우에 학습반복이 중단되는 것을 확인할 수 있다.

표 5는 새로운 변수 조건들의 수식전류와 신경회로망 학습을 이용하여 ± 0.9 % 이내의 오차까지 학습 반복으로 나타낸 예측전류와의 비교를 나타낸 표이다. 각 표본마다 수식전류를 기준으로 ± 0.9 % 이내의 오차를 보여 실용에 충분한 정확도임을 나타내주고 있다.




그림 12. 학습 반복 횟수 증가에 따른 봄, 가을 표본의 오차율변화
Fig. 12. Variation of spring, fall sample due to increase in the number of learning iterations




그림 13. 학습 반복 횟수 증가에 따른 여름 표본의 오차율변화
Fig. 13. Variation of summer sample due to increase in the number of learning iterations

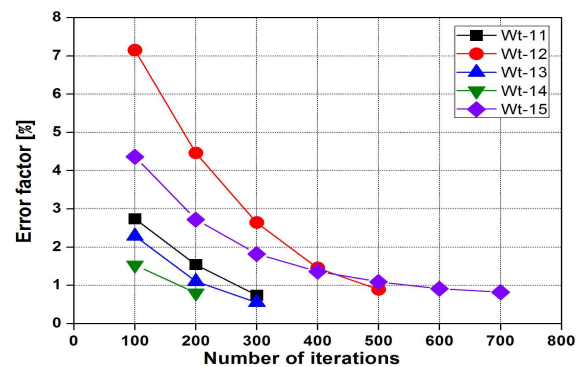


그림 14. 학습 반복 횟수 증가에 따른 겨울 표본의 오차율변화
Fig. 14. Variation of winter sample due to increase in the number of learning iterations

표 5. 수식전류와 예측전류간의 비교
Table 5. Comparison between calculated current and predictive current

표본 번호	수식전류	예측전류	최종 반복 횟수	오차 (%)
Sp-1	1263.7	1274	400	0.82
Sp-2	1317.0	1318	300	0.08
Sp-3	1592.6	1604	300	0.72
Sp-4	1209.0	1219	500	0.83
Sp-5	1127.2	1136	600	0.78
Sm-1	953.5	956	400	0.26
Sm-2	1345.3	1353	400	0.57
Sm-3	1170.1	1179	300	0.76
Sm-4	1183.9	1194	700	0.85
Sm-5	1152.6	1161	500	0.73
Wt-1	1504.8	1516	300	0.74
Wt-2	1262.7	1274	500	0.89
Wt-3	1262.1	1269	300	0.55
Wt-4	1230.2	1240	200	0.80
Wt-5	1101.0	1110	700	0.82

2.4 실제통에서의 적용방안

앞에서 제시한 신경 회로망을 이용한 허용전류 예측 기법을 실 계통에 적용하기 위해서는 송전선 및 일정 위치에 주요 변수들을 측정할 수 있는 센서들을 설치하여 일정 주기마다 데이터를 취득하여 신경회로망에 입력하여 학습할 수 있게 하여야 하며 따라서 설치 후 1년~2년 이내에는 예측 값들에 다소 큰 오차가 있을 수 있다. 그러나 사용 년 수가 증가됨에 따라 데이터 들이 누적되면서 다양한 많은 경험을 가진 장치로 성장하여 예측 값에 오차가 줄어들게 될 것이며 본 연구에서와는 달리 실제 송전선의 열특성에 알맞도록 학습되어 유용하고 신뢰성 있는 결과를 얻을 수 있을 것이다.

3. 결 론

본 연구에서는 현재 허용전류 예측 방법으로 사용되

고 있는 동적 송전용량 산정 방법을 신경 회로망을 이용하여 각 송전선의 현실성이 고려되는 새로운 허용용량 예측 기법을 제시하였다. 제시된 방안은 허용전류 계산식에서 계산결과에 영향력이 높은 변수를 선정하여 그 변수를 토대로 신경회로망에 입력하여 허용전류 값을 예측하는 방안이다. 연구단계에서 정확히 실증하기는 어려운 기법이지만 수식으로 모델링된 가상 송전선을 표본을 통해서 오차 범위가 ± 0.9 % 이내 임을 확인하여 정확성을 입증하였다.

이를 실제통에 적용하기 위해서는 관련 장치들을 현장에 설치하여 해당 송전선의 열적 특성을 경험하여 학습하는 약 1~2년의 기간이 필요하며, 사용기간이 증가됨에 따라 더욱 정확하고 실제 송전선의 현실에 맞는 허용용량예측이 가능해질 것이다.

감사의 글

본 연구는 2011년도 산업통상자원부 재원으로 한국에너지 기술평가원(KETEP)의 지원을 받아 수행한 연구과제(No.2011T100100396)입니다.

References

- [1] Sung-Duck Kim, Seung-Su Lee, Tae-In Jang, Ji-Won Kang, Dong-II Lee, "Short-Term Dynamic Line Rating Prediction in Overhead Transmission Lines Using Weather Forecast System", Journal of KIEE Vol. 18, No. 6, pp. 158-169, 2004.
- [2] Sung-Duck Kim "A Design for Dynamic Line Rating System to increase Overhead Transmission Line Capacities ", Journal of KIEE Vol. 25, No. 7, pp. 72-77, 2011.
- [3] Sung-Duck Kim, "A Reassessment for Dynamic Line Rating of Aged Overhead Transmission Lines in Kepeco's Network", Journal of KIEE Vol. 24, No. 10, pp. 123-129, 2010.
- [4] D. A. Douglass and A. A. Edris, "Real-time monitoring and dynamic thermal rating of power transmission circuits", IEEE Transaction on Power Delivery, vol. 11, no. 3, pp. 1407-1418, 1996.
- [5] Adan M. Gupta, Dandina H. Rao "Neuro-Control System: A Tutorial", Intelligent System Research Lab, Univ. of Saskatchewan, Canada.
- [6] Dae-Soo Kim "Neural Networks Theory and Application (I)" Hi-Tech information, pp. 145~167, 1992n and Application 16 (4) 1986.

◇ 저자소개 ◇



노신의(盧信義)

1987년 7월 12일생. 2012년 숭실대 전기공학과 졸업. 현재 숭실대 대학원 전기공학과 석사과정.

E-mail : nono3005@ssu.ac.kr



임성훈(林成勳)

1996년 전북대 전기공학과 졸업. 1998년 동 대학원 전기공학과 졸업(석사). 2003년 동 대학원 전기공학과 졸업(박사). 현재 숭실대 전기공학 부교수.

E-mail : superlsh73@ssu.ac.kr



김이관(金二寬)

1986년 9월 5일생. 2012년 안양대 전기전자공학과 졸업. 현재 숭실대 대학원 전기공학과 석사과정.

E-mail : yigwan86@hanmail.net



김일동(金一東)

1984년 서울과기대 전기공학과 졸업. 1988년 서울대 전기공학과 졸업(석사). 1996년 서울대 전기공학과 졸업(박사). 현재 두원공과대학교 교수.

E-mail : idkim@doowon.ac.kr