ANN을 이용한 산업현장의 최적 에너지 운용 알고리즘 개발

김섭한*, 김병목*, 김병기*, 노대석*
*한국기술교육대학교 전기공학과
e-mail:k6s6k6@nate.com

Development of Algorithm for Optimal Energy Operation of Industrial Load Using ANN

Seob-Han Kim*, Byeong-Mpk Kim*, Byeong-ki Kim*, Dae-Seok Rho*
*Korea University of Technology and Education

요 약

산업 현장에 필수적으로 사용하는 유틸리티 시스템(Utility System)의 하나인 에어를 생산하는 공기압축기의 운전방식은 조작 패널부에 사용자가 설정한 셋팅값에 의해 내부의 밸브를 제어하여 로딩 및 언로딩 운전을 한다. 이로 인해 대용량(100HP, 200HP)의 공기압축기를 여러대 사용하는 수용가에서는 연속 다발적인 운전으로 인한 전력 사용량의 변동으로 역률 저하 및 연속가동으로 인한 설비 과부하 및 내부 기계 베어링 피로도 증가 및 파손 등 고장이 발생되는 문제점이 있다. 따라서 본 논문에서는 인공 신경회로망(ANN:Artificial Neural Network)을 이용하여 최적의 에너지 운용 알고리즘을 제안하여 실계통의 문제점을 분석하여 개선하고자 한다.

1. 서론

현재 산업 현장에 필요한 유틸리티 시스템(Utility System)의 구성은 크게 전기와 에어로 구성되며, 이 중에서 에어를 생산하는 설비가 공기 압축기(Air Compressor) 이다. 공장의 라인이 자동화 설비로 구축됨에 따라 에어를 사용하는 수요가 높아지고 있으며, 공기압축기 고장발생은 생산 공정이 중단 될 만큼 큰 영향을 끼치고 있다. 규모가 있는 기업에서는 돌발사고를 대비하여 비상 공기압축기를 구축하고 있으나, 규모가 작은 기업에서는 투자비 과다로 인한 여유율을 감안하지 않고 공기압축기 용량선정 및 설치되어 운영되는 상황이다.

공기압축기의 운전 방식은 보통 사용자의 설정 셋팅값(상/하한값)에 의해 로딩 및 언로딩을 반복 하면서 에어를 생산하여 이송 수단인 배관을 통해 공장 설비로 공급된다. 이로 인해 공장이 큰 경우 금속배관 선로저항에 의해 에어압력의 손실이 발생되고, 부하량의 변동이 심한 공장에서는 공기압축기 설치 대수만큼 Full 가동되는 등 설비 과부하로 인한 과열, 내부 기계 베어링 피로도 증가로 인한 파손, 기타 고장발생으로 인해 에어압력 저하로 이어지며 CNC 선반, 밀링, MCT 장비의 공작기계를 사용하는 공장에서는 기계가 가동중에 정지되는 등 경제적인 손실을 초래한다.

따라서 본 논문에서는 이러한 문제점을 해결하기 위해 인공 신경회로망의 다층 프셉트론 이론 및 모델링을 기초로 하여 최적의 에너지 운용 알고리즘을 제안한다.

2. 신경망 이론 및 모델링

2.1 다층 퍼셉트론

하나의 조정층으로 구성되는 모델들의 한계점들 때문에 입력층, 출력층, 그리고 한 개이상의 은닉층을 사용하는 새로운 모델들이 1980년대 중반에 제안되었으며, 특히 PDP(Parallel Distributed Processing) 그룹에 의한 폭넓은 연구가 진행되었다.

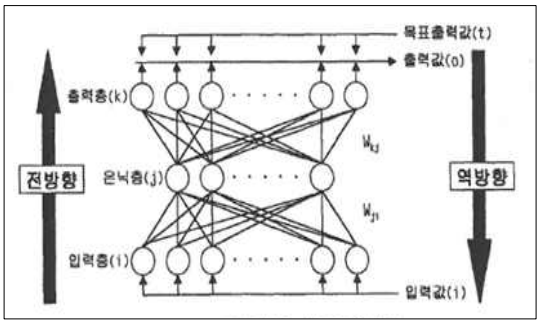

[그림 1] 다층 퍼셉트론의 구조

다층 퍼셉트론(Multilayer Perceptron)은 입력층과 출력층 사이에 하나 이상의 중간층이 존재하는 신경망 구조를 가지고 있으며 그림 1과 같이 나타낸 것과 같은 계층구조를 갖는다.

이때 입력층과 출력층 사이의 중간층을 은닉층(Hidden Layer)이라 부른다. 네트워크는 입력층, 은닉층, 출력층 방향으로 연결되어 있으며, 각 층내의 연결과 출력층에서 입력층으로의 직접적인 연결은 존재하지 않는 전방향의 네트워크이다. 다층 퍼셉트론은 층의 개수가 증가 할수록 고급화된다.

2.2 백프로퍼게이션 학습 알고리즘

다층 퍼셉트론의 대표적인 예가 백프로퍼게이션 학습 알고리즘이다. 백프로퍼게이션 학습 알고리즘은 최소자승(Least Mean Square) 알고리즘의 비선형적인 확장이다. 백프로퍼게이션 학습 알고리즘은 미분의 반복규칙(Chain-rule)을 여러번 반복적으로 적용하여 확률 근사치 프레임워크와 관련 지움으로써 유도해낼 수 있다.

백프로퍼게이션 학습 알고리즘의 기본 원리는 입력층의 각 유닛에 입력 패턴을 주고 중간층을 거쳐 최후 출력층에서 신호를 출력하게 된다. 출력값과 기대값을 비교하여 차이를 줄여나가는 방향으로 연결강도를 조절하고 상위층에서 역전파하여 하위층에서 이를 근거로 다시 자기층의 연결강도를 조정하며 식 (1)과 같이 계산된다.

$$\triangle_p W_{ji} = \eta(t_{pj} - o_{pj}) i_{pi} = \eta\, \delta_{pj}\, i_{pi} \qquad (1)$$

여기서, t_{pj} : p 번째 목표출력 패턴의 j 성분, o_{pj} : p 번째 입력패턴으로부터 네트워크가 계산한 출력의 j 성분, i_{pi} : p 번째 입력패턴의 i 성분, δ_{pj} : 목표출력과 실제출력의 차(오차)

(1) 델타규칙과 최급하강법

델타규칙(Delta Rule)은 입출력 함수가 선형의 유닛으로부터 이루어진 네트워크에 대하여 모든 입력패턴으로 부터 얻어지는 출력과 목표출력과의 오차의 제곱의 총합을 최소로 하도록 연결강도를 조정하는 것이다. 그러기 위해서는 p번째 패턴의 쌍(Pair)을 제시한 경우의 오차의 제곱을 각각의 연결강도로 미분 한 것이 델타 규칙에서의 연결강도 변화량에 비례하는 것을 나타내면 된다. 델타 규칙에 의해 연결강도의 변화가 연결강도 공간상에 주어지는 오차의 제곱을 높이로 하는 곡면에 대하여 최급하강을 한다.

즉, 오차의 제곱이 가장 많이 감소하는 방향으로 변화한다. 이것을 수식적으로 나타내면 다음과 같다. 패턴 p에 대한 오차의 제곱은 식 (2)와 같고 식 (3)은 델타 규칙이 E내에서 최급강하법(Gradient Descent Method)임을 나타낸다. 식 (4)와 같이 모든 패턴을 한번씩 제거한 후의 연결강도의 변화의 총합은 $\partial E / \partial w_{ji}$ 에 비례한다.

$$Ep = 1/2 \sum_j (t_{pj} - o_{pj})^2,\ E = \sum_p E_p \qquad (2)$$

$$-\partial E_p / \partial w_{ji} = \delta_{pj}\, i_{pi} \qquad (3)$$

$$\partial E / \partial w_{ji} = \sum_p \partial E_p / \partial w_{ji} \qquad (4)$$

(2) 백프로퍼게이션 학습 알고리즘의 학습 과정

백프로퍼게이션 학습 알고리즘의 학습과정은 총 13단계로 구성되며, 그림 2와 같다.

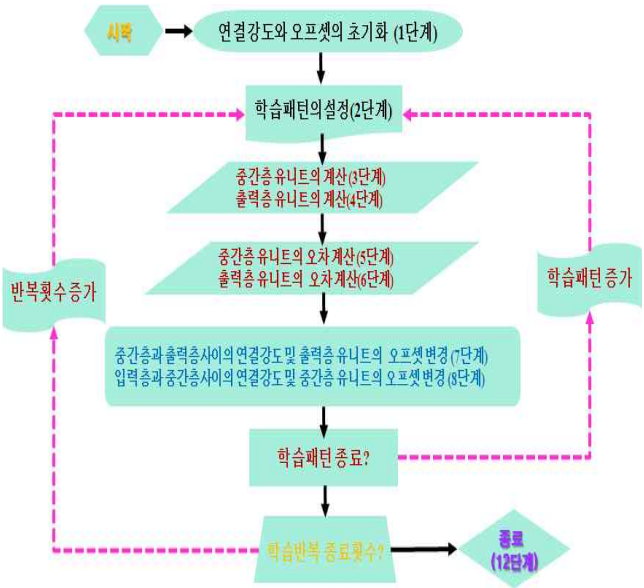

[그림 2] 백프로퍼게이션 학습 알고리즘의 학습과정

<1단계> 네트워크의 상태를 결정하는 연결강도 (W_{ji}, W_{kj})와 오프셋(θ_j, θ_k)을 각각 아주 작은값의 임의 값(Random Value : 난수발생)으로 초기화 한다. (보통 -0.5~0.5 사이의 값 사용)

<2단계> 학습패턴을 설정한다.

<3단계> 학습패턴의 값을 입력층 유니트에 제시하여 출력되는 값 o_{pi}과 입력층과 중간층 사이의 연결강도 W_{ji}, 중간층 유니트의 오프셋 θ_j 을 이용하여

중간층 유니트 j의 입력net_{pj}를 구한다. 다음에 net_{pj}와 시그모이드 함수 f를 이용하여 중간층 유니트의 출력 o_{pk}를 구하면, 식 (5)와 같다.

$$net_{pj} = \sum_i W_{ji} o_{pi} + \theta_j \ , \ o_{pj} = f_i(net_{pj}) \qquad (5)$$

<4단계> 중간층 유니트의 출력값 o_{pj} 중간층과 출력층 사이의 연결강도 W_{kj} 출력층 유니트의 오프셋 θ_k 을 이용하여 출력층 유니트 k의 입력 net_{pk} 를 구한다. 다음에 net_{pk} 와 시그모이드 함수 f를 이용하여 출력층 유니트 k의 출력 o_{pk}를 구하면, 식 (6)과 같다.

$$net_{pk} = \sum_i W_{kj} o_{pi} + \theta_k \ , \ o_{pk} = f_k(net_{pk}) \qquad (6)$$

<5단계> 학습패턴의 목표출력 t_{pk}와 실제출력 o_{pk}d의 차로부터 출력층 유니트 k에 연결된 연결강도와 출력층 유니트 k의 오프셋에 대한 오차 δ_{pk}를 구하면, 식 (7)과 같다.

$$\delta_{pj} = (t_{pk} - o_{pk}) f_k(net_{pk}) = (t_{pk} - o_{pk}) o_{pk}(1 - o_{pk}) \qquad (7)$$

<6단계> 오차 δ_{pk}와 중간층, 출력층간의 연결강도 W_{kj} , 중간층의 출력 net_{pj}로부터 중간층 유니트 j에 연결된 연결강도와 중간층 유니트의 오프셋에 대한 오차 δ_{pj}를 구하면, 식 (8)과 같다.

$$\delta_{pj} = f_i(net_{pj}) \sum_k \delta_{pk} W_{kj} = \sum_k \delta_{pk} W_{kj} o_{pj}(1 - o_{pj}) \qquad (8)$$

<7단계> <5단계>에서 구한 출력층 유니트 k에서의 오차 δ_{pk} , 중간층 유니트 j의 출력 o_{pj} , 정수 α와의 곱을 더하여 중간층 유니트 j와 출력층 유니트 k에 연결된 연결강도 W_{kj}를 수정한다. 또한, 오차 δ_{pk}와 정수 β와의 곱을 더하여 출력층 유니트의 k의 오프셋 θ_k를 수정하며, 식 (9)와 같다.

$$W_{kj} = W_{kj} + \alpha \delta_{pk} o_{pj} \ , \ \theta_k = \theta_k + \beta \delta_{pk} \qquad (9)$$

<8단계> 중간층 유니트 j에서의 오차 δ_{pj}, 입력층 유니트 I의 출력 o_{pi}, 정수 α와의 곱을 더하여 입력층 유니트 I와 중간층 유니트 j에 연결된 연결강도 W_{ji}를 수정한다. 또한, 오차 δ_{pj}와 정수 β와의 곱을 더하여 중간층 유니트 j의 오프셋 θ_j를 수정하며, 식 (10)과 같다.

$$W_{ji} = W_{ji} + \alpha \delta_{pj} o_{pi}, \ \theta_j = \theta_j + \beta \delta_{pj} \qquad (10)$$

<9단계> 다음 패턴을 학습시킨다.
<10단계> 모든 학습패턴에 대하여 전부 학습할 때까지 <2단계> 로 되돌아 간다.
<11단계> 학습의 반복 횟수를 센다.
<12단계> 학습의 반복 횟수가 제한 횟수보다 작으면 2단계로 되돌아 간다.
<13단계> 종료한다.

3. 최적 에너지 운용 알고리즘

3.1 실계통 문제점 분석

공기압축기의 총 사용량을 표 1을 참조하면 주간인 경우 에어 소모량(185㎥)과 야간인 경우 에어 소모량(169㎥)이 다소 차이가 있어 주간은 공기압축기 6대로 Full 가동 중이며, 1~2대 고장이 발생할 경우 일부 라인 계획정지가 불가피한 상황이다. 야간에는 주간부하에 비해 에어 소모량이 감소하여 로딩 및 언로딩 설정 범위가 작아져 모터 및 펌프 수명 단축에 악영향을 주고 있다. 이와 같이 부하량의 변화에 따라 공기압축기 운용에 대한 문제점들이 혼재되어 있어, 이에 대한 검토와 대책 마련이 시급하다.

[표 1] 라인별 에어사용 현황

팀명	설비대수(대)	근무 형태	에어 소모량(㎥)
생산1팀	15	주/야	23
생산2팀	15	주	11
생산3팀	15	주	5
생산4팀	19	주/야	11
생산5팀	68	주/야	80
생산6팀	35	주/야	40
생산7팀	28	주/야	15
합계	***195***		***185***

3.2 공기 압축기 설치 현황

충남 아산에 위치한 (주)센트랄모텍 아산공장에서는 자동차 부품을 생산하는 조립라인 및 가동라인으로 설비가 구축 되어져 있다. 근무형태는 주/야간

(2Shift)으로, 공기압축기는 총 6대(700HP)로 운용중이며, 공기압축기 설치 구성도는 그림 3과 같다.

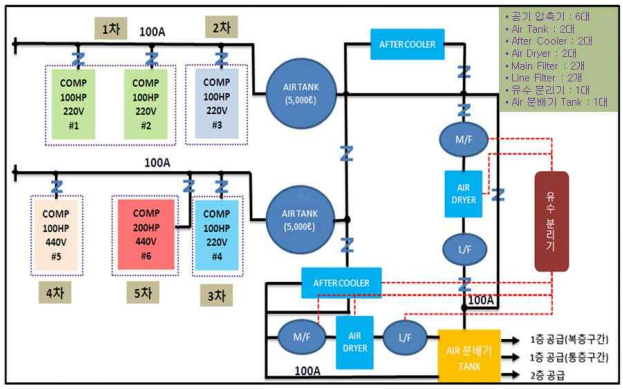

[그림 3] 공기압축기 설치 구성도

3.3 ANN을 이용한 모델계통 해석

(1) XOR-Program를 이용한 프로그램 설계

백프로퍼게이션 학습알고리즘을 이용하여 공기압축기 2대를 이용한 XOR-Program 포트란 소프트웨어 로 프로그램을 설계하여 하였으며, 그림 4와 같다.

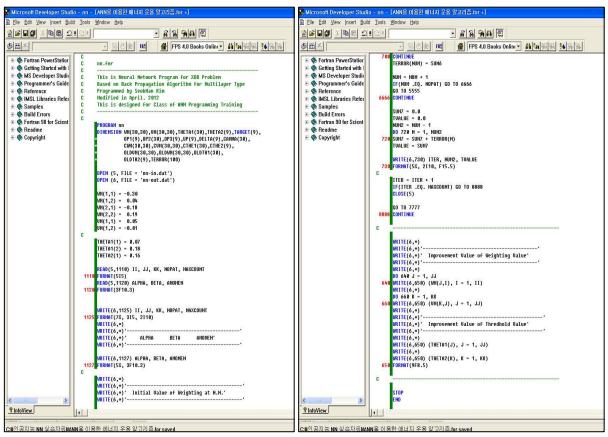

[그림 4] 포트란 프로그램 설계 메인 화면

XOR-Program 결과 값은 그림 5와 같다.

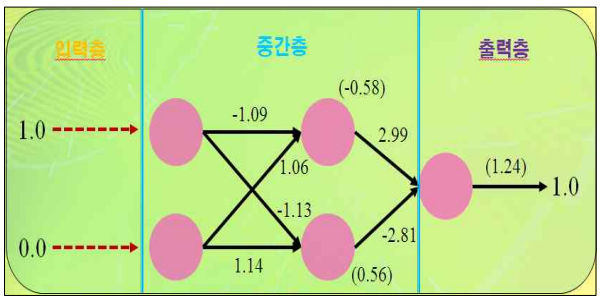

[그림 5] 프로그램 결과값

(2) 예상 에너지 절감 및 효율 비교

첫 번째로, 에너지 절감에 의한 비교를 하면 그림 6과 같이 연간 약 5백만원의 에너지 절감 효과가 발생할 것으로 추정된다.

※기준 : 100 Hp=75 Kwh 사용, Air 생산용량 : 13.88 ㎥/min, 1Kwh = 11.10 ㎥/min

구분	1Kwh당 Air생산량	75Kwh(=100Hp) Air생산량	1年 운전 에너지 절감 비용 [기준 : 3,000hr=일수 : 125日, 24hr Full 가동 / 1Kwh당 78원]
기존방식 -운전 형태 : Load ☞ 70%, Unload ☞ 30%	7.772 ㎥/hr	582.90 ㎥/hr	▪ 1hr당 생산량 절감 ☞ 변경 後 - 변경前 = 824.4㎥/hr - 582.90㎥/hr = 241.5 ㎥/hr ▪ 계산식 ⓐ 241.5㎥/hr × 3,000hr = 724,500㎥/hr ⓑ 724,500㎥/hr / 11.10 ㎥/hr = 65,270Kwh ⓒ 65,270Kwh × 78원 = 5,091,081원/年 ⓓ 3年 × 5,091,081원 = 15,273,243원 (5年 = 25,455,405원)
ANN 운용 알고리즘 -운전 형태 : Load ☞ 99%, Unload ☞ 1%	10.992 ㎥/hr	824.4 ㎥/hr	

[그림 6] 에너지 절감 비용

두 번째로, 효율에 따른 절감을 비교를 하면 그림 7과 같이 연간 약 1백만원의 에너지 절감 효과가 발생할 것으로 추정된다. 첫 번째와 두 번째 금액을 합산해 보면 연간 6백만원의 절감 효과가 예상된다.

※기준 : 100 HP=75 Kwh시 7.0 kg/㎠ 사용, 1 kg/㎠ 소비 전력량: 6.6Kwh

구분	운전 압력차이	Hr당 운전 소비전력(Kwh)	1年 운전 에너지 절감 비용 [기준 : 3,000hr=일수 : 125日 / 1Kwh당 78원]
변경前(기존 방식) -운전 형태 : Load ☞ 6.0 kg/㎠, Unload ☞ 7.0 kg/㎠	1.0 kg/㎠	74.82Kwh (7.0 kg/㎠)	▪ 1hr당 소비전력 절감 ☞ 변경 前 - 변경後 = 74.82Kwh - 70.40Kwh = 4.42Kwh ▪ 계산식 ⓐ 4.42Kwh × 3,000hr × 78원 = 1,034,280원/年 ⓑ 3年 × 1,034,280원 = 3,102,840원 (5年 = 5,171,400원)
ANN 운용 알고리즘 -운전 형태 : Load ☞ 6.0 kg/㎠, Unload ☞ 6.3 kg/㎠	0.3 kg/㎠	70.40Kwh (6.3 kg/㎠)	

[그림 7] 효율 및 전체 절감비용

4. 결 론

본 논문에서는 인공 신경회로망의 다층 프셉트론 이론 및 모델링을 기초로 하여 최적의 에너지 운용 알고리즘을 제안하여, 실계통의 문제점을 분석하고 해결방안을 제시하였다.

이 운용 알고리즘을 실계통의 소프트웨어와 하드웨어에 접목시켜 적용 한다면 효율적이고 최적화된 공기압축기 관리시스템이 될 것으로 사료된다.

참고문헌

[1] 노대석외 1인, “분산전원이 연계된 배전계통에 있어서 ANN을 이용한 최적 전압조정방안에 관한 연구”, 한국산학기술학회 논문지, 제10권, 제11호, pp. 3130-3136, 11월, 2009.