

인공신경망을 이용한 도로터널 오염물질 농도 예측

이덕준^{1)*}, 유용호¹⁾, 김진²⁾

Application of Artificial Neural Network to the Prediction of Pollutant Concentration in Road Tunnels

Duck-June Lee, Yong-Ho Yoo and Jin Kim

Abstract In this study, it was purposed to develop the new method for the prediction of pollutant concentration in road tunnels. The new method was the use of artificial neural network with the back-propagation algorithm which can model the non-linear system of tunnel environment. This network system was separated into two parts as the visibility and the CO concentration. For this study, data was collected from two highway road tunnels on Yeongdong Expressway. The tunnels have two lanes with one-way direction and adopt the longitudinal ventilation system. The actually measured data from the tunnels was used to develop the neural network system for the prediction of pollutant concentration. The output results from the newly developed neural network system were analysed and compared with the calculated values by PIARC method. Results showed that the prediction accuracy by the neural network system was approximately five times better than the one by PIARC method. In addition, the system predicted much more accurately at the situation where the drivers have to be stayed for a while in tunnels caused by the low velocity of vehicles.

KeyWords Prediction of pollutant concentration, Artificial Neural Network, Back-Propagation Algorithm

초 록 본 연구에서는 비선형 모델에 적용 가능한 역전파 알고리즘을 이용하여 도로터널에서 발생하는 오염물질을 예측하기 위한 인공신경망을 개발하였다. 도로 터널에서 중요시되는 오염인자는 CO농도와 가시도이므로, 인공신경망의 구성을 각각의 독립적인 네트워크로서 구성하였다. 사용한 입력 데이터는 영동고속도로에 위치한 종류식 환기 방식을 채택한 일방향 2차선 도로 터널 2개소에서 실측한 데이터를 사용하였다. 예측치와 실측치를 비교할 때 인공신경망의 학습도는 약 95%의 정확성을 보이는 것으로 나타났다. 분석결과 개발된 인공신경망에 의한 결과는 PIARC 방식에 의한 계산치 보다 약 5배 정도의 정확성을 보였다. 특히 주행속도가 낮을 경우 더 높은 정확도를 나타낼 것으로 기대 되었다.

핵심어 오염물질예측, 인공신경망, 역전파알고리즘

1. 서 론

국토의 대부분을 산지가 차지하고 있는 우리나라의 특성상 고속도로에는 수많은 터널을 포함하고 있다. 게다가 물류비용 감소를 위해 차량 속도를 높이려고 도로를 직선화하는 추세에 따라 터널의 비율이 급증하고 있으며 터널의 길이도 장대화 하는 경향을 보임으로써 터널내의 효율적인 환기방안에 관심을 기울이고 있다. 이러한 터널 환기는 많은 변수의 함수로서, 국내 도로

터널 환기 시스템 설계의 경우 최근까지도 국내 여건과는 다른 조건임에도 불구하고 외국의 경험 및 설계기준에 전적으로 의존하여 터널내부의 오염물질 발생을 예측하고 있어 많은 문제점을 안고 있다. 근래 국내의 도로터널 환기시스템 설계에 가장 폭넓게 적용되고 있는 것은 PIARC (Permanent International Association of Road Congresses) 방식이다. 그러나 PIARC 방식에 적용되고 있는 많은 계수들은 국내 터널에 그대로 적용하기에는 다소 무리가 따른다. 특히 이 방식에서 적용되고 있는 연평균 일일 교통량(AADT)의 경우 이미 많은 연구를 통하여 적용 불가능함이 보고 되고 있으며, 기술발달에 따른 차량의 매연배출량 감소를 적절하게 반영하지 못하고 있는 실정이다.¹⁻⁴⁾

최근 계획되는 터널의 장대화는 작은 단면적의 증가

¹⁾ 비회원, 인하대학교 환경토목공학부 박사과정

²⁾ 정회원, 인하대학교 환경토목공학부 교수

*교신저자(Corresponding Author): djlee1118@orgio.net

접수일: 2003년 10월 6일

심사 완료일: 2003년 11월 3일

에도 매우 큰 공사비의 증가가 요구되므로, 다른 환기 방식과 비교할 때 비교적 단면적이 작은 종류식 환기 방식을 채택하고 있다. 아울러, 도심지 근방의 교통량이 많은 터널을 제외한 대다수의 터널이 2차선이고, 교통 환기력의 충분한 활용을 위해 일방향 터널로 설계된다. 따라서, 본 연구에서는 장대터널의 주를 이루게 될 것으로 예상되는 종류식 환기 방식을 채택한 일방향 2차선 도로 터널을 주요 연구 대상으로 선정하였으며, 도로터널 내에서 발생하는 물질 중 생리적인 영향을 미치는 CO 가스와 가시거리를 저해하여 안전운행에 영향을 주는 매연의 발생량을 예측하였다. 이를 위하여 인간이나 동물들이 가지고 있는 생물학적인 뇌의 신경세포(Neuron)를 모델화하여 인공적으로 지능을 만드는 인공신경망을 이용하였다. 인공신경망은 특성상 오염물질의 예측시 계수의 영향을 받지 않아 전술한 PIARC 방식에 의한 문제점을 발생하지 않는다. 다시 말해 인공신경망은 실제 터널에서 실측된 오염물질의 농도 및 변화량을 이용하여 반복적인 학습을 시켜 인간의 두뇌가 나타내는 지능적 형태를 구현하는 방식이므로 그 내부에서 발생하는 작용을 알 수 없는 블랙박스(Black box)와 같은 형식으로 터널내 오염물질을 예측한다. 따라서, 학습된 인공지능형 터널 오염물질 예측 시스템의 개발은 종래의 터널 환기 설계 기법들의 실제와의 차이에 생길수 있는 과실계를 방지하여 보다 효율적인 터널 환기 설계를 위한 첫걸음으로서 많은 기여를 할 것으로 기대 된다.

2. 인공신경망

인공신경망은 인간의 뇌에 존재하는 생물학적 신경세포와 이들의 연결 관계를 단순화시켜 수학적으로 모델링하여 인간의 두뇌가 나타내는 지능적 형태를 구현한다. 따라서 인공신경망은 연속적인 학습에 의해 이전의 데이터를 보간(Interpolation)하는 방식으로 복잡한 비선형 시스템의 제어에 적합하다고 할 수 있다.⁵⁻⁷⁾ 현재 신경 회로망 기법은 제어기 설계, 패턴 인식, 최적화 문제 등에 광범위하게 응용되고 있으며 제어 시스템에 응용되는 대표적인 기법으로는 기존의 선형 제어 방식과 신경 회로망을 결합한 방식을 들 수 있다.⁸⁻¹⁰⁾ 현재 신경망 알고리즘 중 역전파(Back-propagation) 방식이 사용상의 용이성 때문에 가장 많이 쓰이는 알고리즘이다. 역전파방식은 내부적인 귀환항이 없기 때문에 정적인 맵핑이라고 불린다. 구조적으로 출력층, 다수의 은닉층, 입력층으로 구성되지만, 출력층과 하나의 은닉층, 입력층으로 충분히 비선형 시스템의 동작과 제어가 가능하

다.¹¹⁻¹²⁾ 역전파알고리즘은 입력 벡터(Vector)가 나열되어있는 예제를 통해 반복적으로 출력을 각각의 입력에 따라 수정해가며 학습한다.

각각의 학습파일을 거치는 것이 하나의 주기이다. 각 주기동안 네트워크는 실제의 결과를 가지고 목적하는 결과와 비교해서, 에러를 산출한 뒤, 그 에러를 최소화하기 위해 가중치(Weight)를 조절한다.¹³⁾ Supervised Training이라 불리는 이 과정을 통해, 네트워크는 올바른 결과와 입력 패턴을 연관시키는 것을 학습하게 된다. 누적된 변화 값은 네트워크가 학습한 것을 나타내며, 학습한 방법을 보존하는 가중치(Weight)를 저장하는 것을 나타낸다.¹⁴⁾

일반적으로 출력층에서 나온 결과 벡터(O_{pi})는 실제의 결과 벡터(T_{pi})와는 같지 않다. 이들 간의 오차는 다음과 같이 계산된다.

$$E_p = \frac{1}{2} \sum (T_{pi} - O_{pi})^2 \quad (1)$$

전체 오류는 학습 오류의 합으로서 계산된다.

$$E_t = \sum E_p \quad (2)$$

학습 오류를 감소시키기 위해서 가중치는 전방향전파와 역전파를 반복하면서 가중치를 변화 시킨다. 식 (1)과 식 (2)는 이러한 계산을 수행하게 된다. 이러한 처리는 정해진 역치오류(Threshold error)까지 계속 수행된다. 신경망의 오류는 일반적으로 RMS(Root mean squared error) 혹은 SSE(Summed squared error)를 사용하여 최소로 수렴되기까지 계속된다.

2.1 인공 신경망 기본 설정

본 연구에서는 인공 신경망을 이용한 종류식 환기 방식을 채택한 도로 터널에서의 오염물질 농도를 예측하기 위한 시스템이므로, 입력 인자들 선정은 도로 터널의 환기에 적용되는 인자들 중 독립적인 인자를 선정하였다.¹⁵⁾ 이러한 도로 터널 환기에 적용되는 인자들로는 크게 3가지로 구분할 수 있는데, 자연적인 인자들과 터널의 외형적 인자들, 터널내 교통량에 관계되는 인자들로 구분 할 수 있다.

자연적인 인자

자연적인 인자는 측정시간, 자연풍속(방향포함)을 입력 인자로 선정하였다. 이는 측정시간별 교통량의 차이와 자연풍의 세기에 따른 오염물질 농도와 관련된다.

터널에 관계되는 인자

터널에 관계되는 인자중에서 터널길이, 구배, 고도, 단면적을 입력 인자로 사용하였다. 터널에 관계되는 인자들 중 입·출구 손실계수, 터널 대표 직경은 터널 단면적에 관계되는 인자들이므로 터널 단면적으로 통합하여 고려하였고 터널 고도 보정계수는 터널 고도에 관계되는 인자이므로 터널 고도로 통합·고려하였다. 터널 구배 보정계수 또한 터널 구배로 통합 고려하였다. 터널길이는 터널 개개의 특성 인자이므로 별도로 고려하였다.

교통 관련 인자

교통 관련 인자들 또한 투영면적, 대형차 혼입률, 자동차 저항계수는 교통량에 관계되는 인자들이므로 교통량으로 통합하였고, 차종별·주행 속도별 오염물질 배출량은 평균 주행속도에 관련되는 인자들이므로 평균 주행 속도로 통합하였다. 따라서 교통량에 관련된 인자 중에서 교통량, 평균 주행속도를 입력 인자로 사용하였다.

최종적으로 선택된 8개의 독립적인 인자는 측정시간, 자연풍속, 터널길이, 구배, 고도, 단면적, 교통량, 평균 주행속도이다. Fig. 1은 구성된 인공신경망의 구조도이

다. 개발된 인공신경망은 기본적으로 8개의 입력인자를 받아들이는 입력층(Input layers)과 4개의 은닉층(Hidden layers) 그리고 출력층(Output layer)으로 이루어져 있다.

2.2 인공신경망의 학습

개발된 인공신경망의 학습에 사용된 데이터는 영동고속도로에 위치한 ○○ 터널과 △△ 터널에서 실측된 실측치이다. ○○ 터널의 경우 한국 도로 터널중 최고지에 위치하는 해발 682.2 m의 높이에 설치된 터널로써 연장 3,260 m의 장대터널이며, △△ 터널은 해발고도 629 m의 고산지대를 관통하는 연장 1,445 m의 터널이다.

학습률 및 오차한도

개발된 인공신경망에 인공지능을 부과하기 위한 학습에 사용한 인자들은 수치적 차이에서 오는 영향성을 배제하기 위하여 각 인자들의 실제 값을 10~1,000으로 나누어 준 수치를 사용하였다. 또한 신경망의 정규적인 학습규칙인 가중치 변화에는 비례상수인 학습률(learning rate)만을 고려하였으며, 부가적으로 수렴을 도와 줄 수 있는 모멘텀계수(momentum coefficient)는 적용하지 않았다. 그러나 1,000,000번과 30,000,000번의 수많은

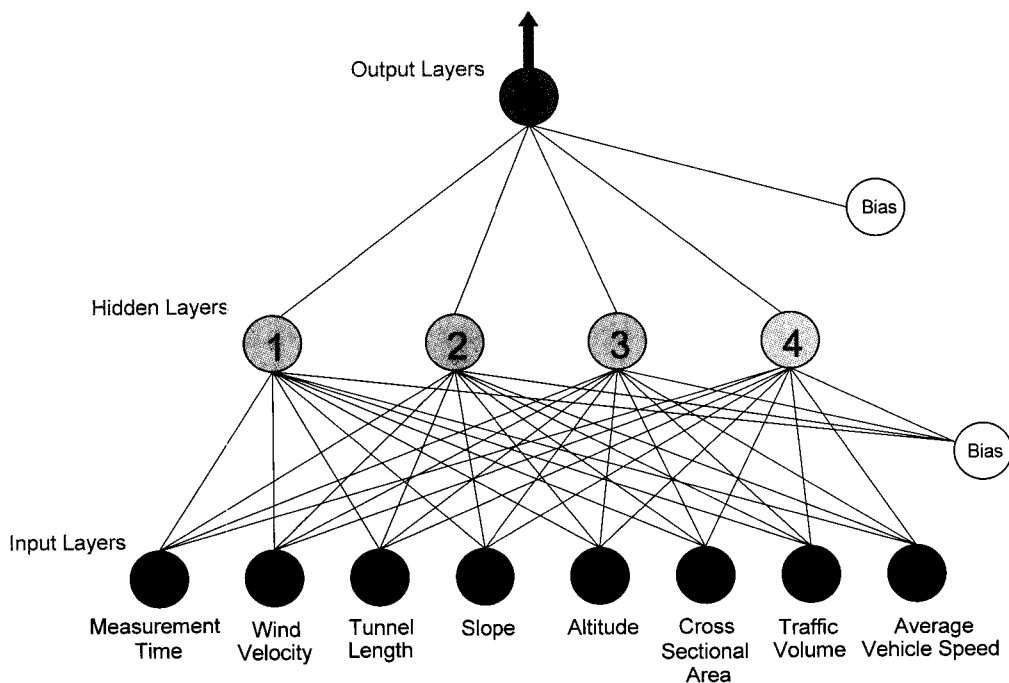
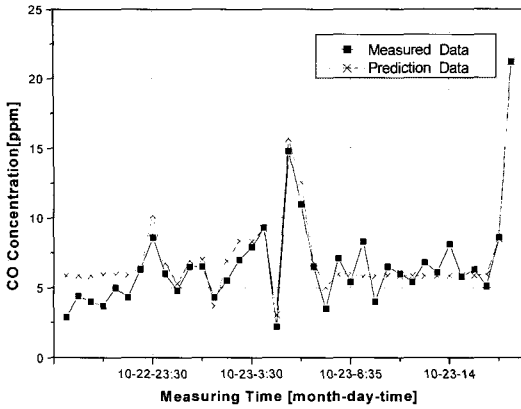



Fig. 1. Structure chart of the neural network



(a) Measured data vs. neural network



(b) Error percent of CO concentration

Fig. 2. CO concentration(○○tunnel): compared neural network with measured data

반복 학습으로 오차한도 1×10^{-8} 에 수렴하여 충분한 학습이 이루어졌음을 확인하였다.

2.3 인공신경망 학습

학습된 인공지능의 검증 위하여 ○○ 터널과 △△ 터널의 실측된 CO농도 및 가시도를 인공신경망을 통한 예측치와 비교하였다.

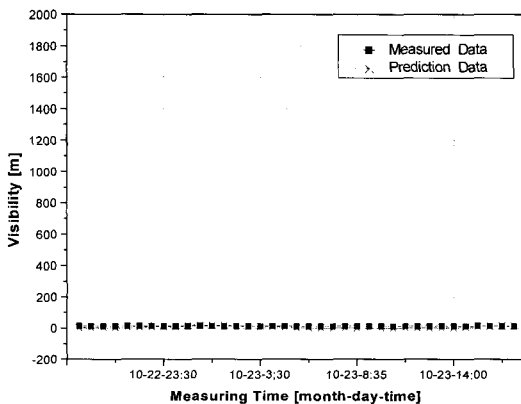
○○ 터널(CO 농도)

Fig. 2 (a)는 ○○터널에서 CO 농도 실측 데이터와 학습된 인공신경망에 의한 결과를 비교하였으며, Fig 2 (b)에서는 그에 따른 오차율을 별도로 나타내었다. 최대 오차율은 102%이고 최소 오차율은 0.05%를 나타내며, 농도가 높은 경우 오차가 작아지고 농도가 낮은 경우

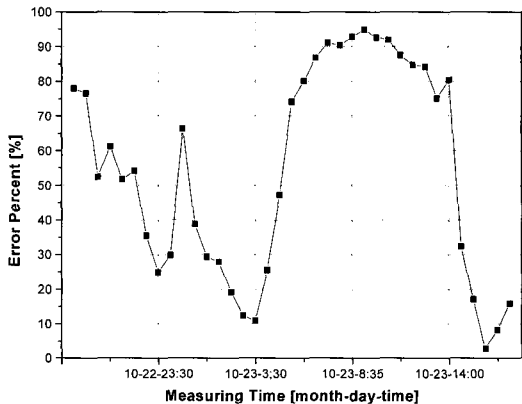
오차가 커지는 현상을 보인다. 이는 농도가 작은 경우 (2.9 ppm)에 인공신경망에 의한 결과치가 정량적으로 작은 값의 차이(약 3 ppm)를 보여도 상대적인 오차가 크게 보이기 때문이나 거의 무시할만한 수준이라 생각 된다. 하지만 도로 터널에서 오염물질 허용 기준치를 넘어가는 농도가 높은 경우에 있어서 오차가 작아지므로 농도가 높은 경우에 보다 정확하게 예측할 수 있을 것으로 판단된다.

○○ 터널(가시도)

인공신경망에 의한 매연농도 결과치를 가시도로 환산하여 실측치와 비교하였다. 그 결과는 Fig. 3 (a)와 같으며 오차율은 Fig. 3 (b)이다. 터널 길이가 3,260 m의 장대 터널이므로 가시도는 10~15 m의 매우 낮은 범위이

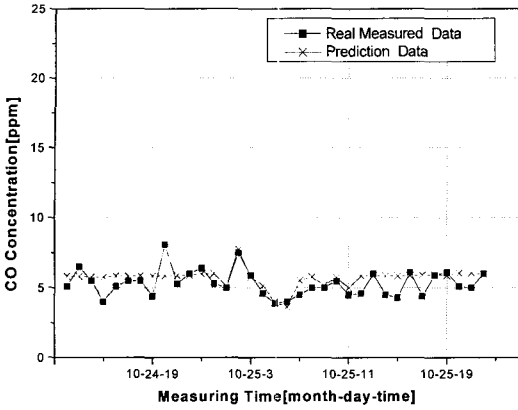


(a) Measured data vs. neural network

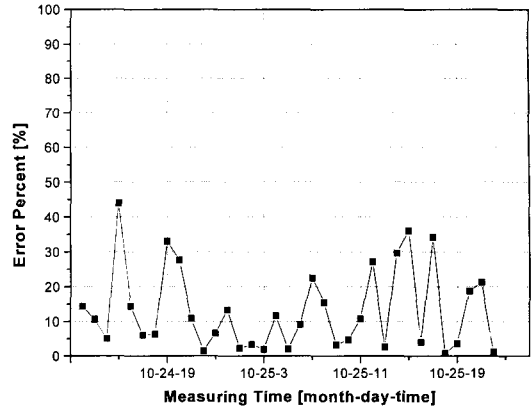


(b) Error percent of visibility

Fig. 3. Visibility: compared neural network with measured data



(a) Measured vs. neural network



(b) Error percent of CO concentration

Fig. 4. CO concentration($\Delta \Delta$ tunnel): compared neural network with measured data

다. 따라서, 전술한 경우와 같은 이유로 인공신경망에 의한 결과가 실측치와 작은 차이를 보여도 오차가 매우 큰 것처럼 느껴지나 정량적으로는 무시될 만한 수준이다. 오차율의 범위는 2.7~94.9%이다.

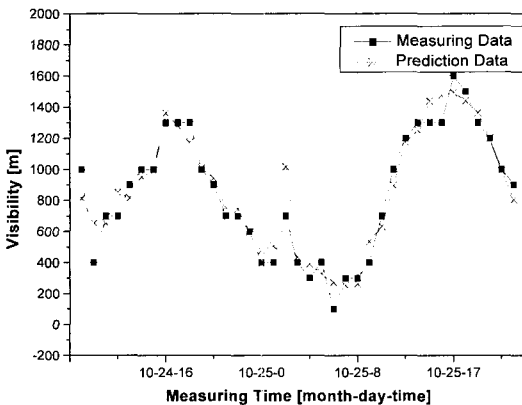
$\Delta \Delta$ 터널(CO 농도)

Fig. 4 (a)는 $\Delta \Delta$ 터널의 CO 농도 실측치와 인공신경망에 의한 결과를 비교하여 나타내었다. 앞선 터널의 결과와 유사하게 CO 농도에 대한 인공신경망의 결과치는 실측치와 동일한 양상을 보인다. 실측 데이터는 3.9~8.1 ppm의 범위이며 $\circ \circ$ 터널과 비교할 때 낮은 분포를 보인다. Fig. 4 (b)는 CO 농도 실측치와 인공신경망에 의한 결과치와의 오차율이며, 범위는 0.8~43.9%이다.

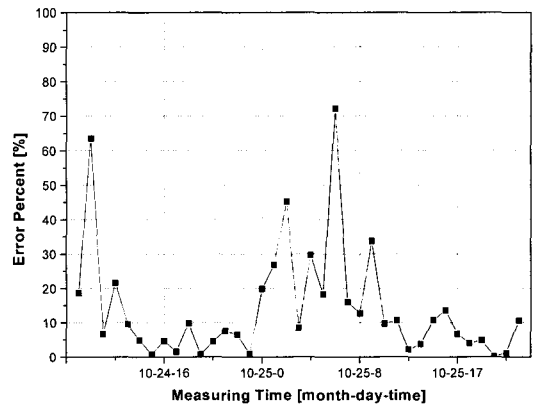
$\Delta \Delta$ 터널(가시도)

$\Delta \Delta$ 터널의 경우 $\circ \circ$ 터널과 달리 가시도 수치가 높은 범위이므로 (172~1,493 m) 오차율이 작은 경향을 보인다. Fig. 5 (a)는 실측치와 인공신경망에 의한 가시도의 비교이며, Fig. 5 (b)는 가시도 오차율을 나타내고 있다. 전술한 경우와 동일한 이유로 오차율 0.1~72.2% 정도로 가시도의 오차가 크게 분포되는 것으로 보이나 Fig. 5 (a)에 보이는 바와 같이 실측치와 인공신경망의 의한 결과치는 거의 동일한 값을 나타내고 있음을 알 수 있다.

이상에서 살펴본 CO 농도와 가시도 검증 결과 인공신경망에 의한 결과는 실측치와 거의 동일한 변화양상을 보이며 주요 범위에서는 실측치와의 오차도 큰 차이가 없는 것을 확인할 수 있었다. 다만 수치가 작은 범위



(a) Measured and neural network



(b) Error percent of visibility

Fig. 5. Visibility($\Delta \Delta$ tunnel): compared neural network with measured data

인 경우 오차가 다소 크게 보이거나 보이는 오차율에 비해 정량적인 수치에서는 매우 작은 값의 차이로 무시할 만 수준이었다. 따라서, 학습된 인공 신경망은 ○○ 터널과 △△ 터널 데이터의 반복적인 학습을 통하여 충분한 인공지능을 획득하였다고 판단된다.

3. 인공 지능과 PIARC 방식 비교

학습을 통하여 인공지능이 부여된 예측 시스템을 이용하여 종류식 환기 방식을 채택한 일방향 2차선 도로 터널인 □□ 터널의 오염물질 농도를 예측하여 기존의 국내 도로터널 환기시스템 설계에 적용되고 있는 PIARC 방식과 비교하였다. □□ 터널은 해발 표고 147 m에 위치한 1450 m의 연장을 가지는 터널로서 일방향 2차선 터널이다. 제트팬은 $\phi 1030$ 제트팬 20대가 설치

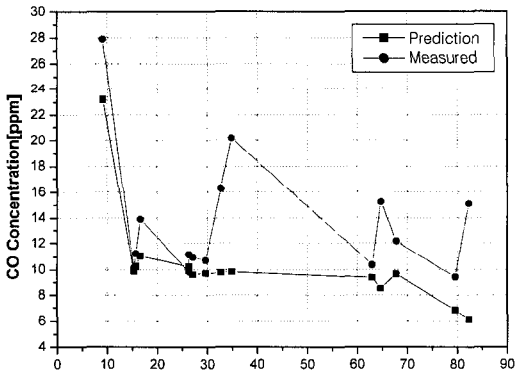
되어 있다.

3.1 학습된 인공 신경망을 이용한 예측


학습된 인공신경망을 이용한 경우 Fig. 6에서 보여 지듯이 CO 농도와 가시도 모두 실측 데이터와 유사한 경향을 나타내고 있다. 특히 주행속도가 낮아서(30 km/h 이하) 운전자들이 터널을 통과하는 시간이 길어지는 경우에 보다 높은 정확성을 보인다. Fig. 6 (a)는 CO 농도 예측 그래프이며, Fig. 6 (b)는 가시도 예측 그래프이다. 예측치와 실측치간의 오차는 CO의 경우 2~59%이며 가시도는 0.1~33%이며, 인공신경망의 적용이 매우 잘 일치하고 있었다.

3.2 PIARC 방식을 이용한 예측

기존의 PIARC 방식은 적용 교통량을 이용한 오염물

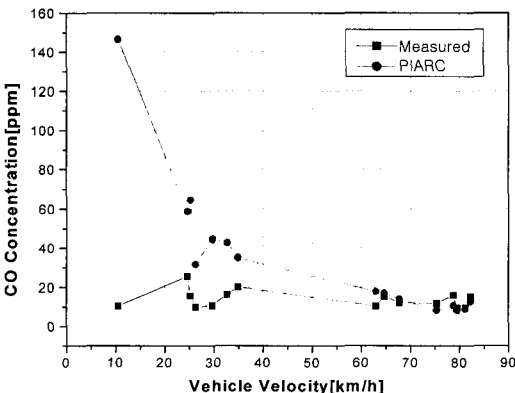


(a) Predicted CO concentration by neural network




(b) Predicted visibility by neural network

Fig. 6. Prediction of CO concentration and visibility by neural network



(a) Predicted CO concentration by PIARC



(b) Predicted visibility by PIARC

Fig. 7. Prediction of CO concentration and visibility by PIARC

질 농도 예측의 경우 실측 데이터와의 차이가 너무 클 뿐 아니라 이미 기존에 적용 교통량의 문제점이 보고되고 있다. 적용 교통량(연평균 일 교통량: AADT)으로 소요 환기량을 산정하는 방식은 교통량이 달라도 차량의 구성비가 같은 경우에 소요 환기량이 같은 단점이 있다. 이에 PIARC에서 제시하는 교통 밀도식을 수정하여 기존의 적용 교통량을 사용하지 않고, 추정 교통량(첨두 설계시간 교통량: PDDHV)을 사용하여 오염물질 농도를 예측하였다. 이러한 PIARC 방식과 인공신경망에 의한 예측치를 비교하면 다음과 같다.

Fig. 7 (a)는 실측 데이터와 PIARC 방식의 CO 농도 예측치를, Fig. 7 (b)는 가시도 도시한 그래프이다. Fig. 7 (a)에서 나타나듯이 운행 중인 차량이 터널 내에 지체되는 시간이 길어지는 저속에서 그 오차가 커지고 있다. 실측 데이터와 비교할 때 PIARC 방식의 경우 CO 농도는 5~1,310 %의 오차를 보임으로서 그 적용성 여부를

재고해야 할 것으로 판단된다. 또한, Fig. 7 (b)에서 보이는 바와 같이 가시도의 경우 주행 속도가 10 km/h인 경우를 제외하면 실측치 보다 낮은 분포를 나타낸다. 이는 환기 설비의 지나친 운전을 야기시켜 환기의 효율적인 운전을 방해할 것으로 판단된다. PIARC 방식과 실측 데이터간의 가시도 오차는 26~82% 이다.

3.3 인공지능과 PIARC 방식 비교 결과

현재 우리나라에 적용하고 있는 PIARC 방식의 국내 적용시 일부 터널을 제외하고 주행속도가 10 km/h인 경우에 있어서 환기 설비가 맞춰지고 있음을 감안할 때 이상에서 살펴본 바와 같이 소요 환기량이 과적용되고 있음을 알 수 있다. 이러한 PIARC 방식의 오염물질 농도 예측에서 오차율이 큰 이유는 몇 가지로 예상된다. 우선 첫째로, 차량의 성능이 발전함에 따라 개선되고 있는 오염물질 배출량 감소를 적절히 고려하지 못하기







Fig. 8. Predicted CO Concentration for each factor


때문이다. 다시말해, 차량의 주행시 발생하는 오염물질의 농도에 관한 가장 최근의 데이터가 1996년도 데이터로서 현재의 차량 오염물질 발생 상황과 맞지 않는다. 두 번째로 PIARC 방식에 적용된 여러 계수들이 국내 실정에 맞지 않고 외국의 설계에 의존하여 이루어지고 있는 실정이 이러한 오차의 원인이라 판단된다. 따라서 외국의 기준에 맞춰 설계된 계수들을 국내의 터널 설계시에 적용함에 있어서 보다 많은 연구를 통하여 그 타당성 여부의 검토가 필요할 것이다. 셋째로, 교통용량 산정의 문제이다. 앞에서 언급한 바와 같이 기존의 적용 교통량을 적용할 경우 차량 구성비가 동일할 경우 교통량이 달라도 소요 환기량이 같은 문제가 있다. 이러한 문제점들을 감안할 때 국내 도로터널 설계시 소요 환기량 산정을 위해 PIARC 방식의 적절한 개선이 필요할 것이다.

4. 인자별 오염물질 농도 예측

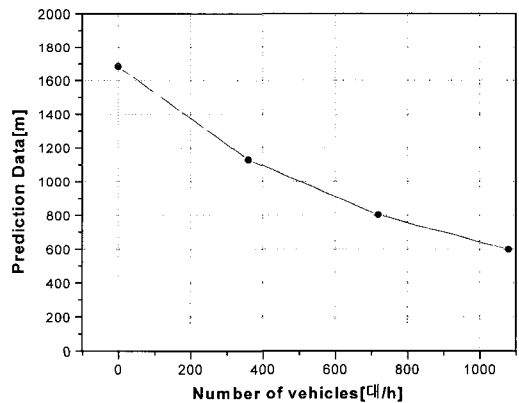
학습된 인공신경망을 이용하여 인자별 CO 농도와 가시도 변화를 예측하였다. 사용된 8개의 인자들중에서 실제 터널에서 변화 가능한 인자 4개(측정 시간, 차량대수, 외부풍속, 주행속도)를 선정하였으며, 각 인자들은 ○○ 터널과 △△ 터널에서 측정된 데이터의 변화 범위 내에서 오염물질 농도를 예측하였다. 인자별 예측 범위는 측정시간은 0~24시, 차량대수는 10~1,800 대/h, 주행속도는 0~180 km/h, 외부풍속은 0~5 m/s이다.

4.1 인자별 CO농도 예측


Fig. 8은 각각의 인자들의 변화에 따른 인공신경망에 의한 CO 농도 예측치이다. 차량 대수가 10~1,800 대/h로 증가함에 따라 CO 농도는 25~7.5 ppm으로 감소한다. 주행속도는 10~180 km/h로 증가함에 따라 24.9~



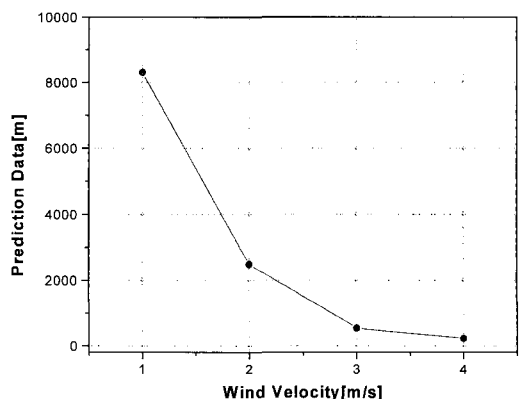
(a) Measuring time



(b) Number of vehicles



(c) Vehicle velocity



(d) Air velocity

Fig. 9. Predicted visibility for each factor

3.8 ppm으로 감소하며, 외부풍속의 경우 0~5 m/s의 변화 범위에서 25~5.9 ppm의 변화폭을 보인다. 위 결과를 종합하여 볼 때, CO 농도는 예상했던 바와 같이 주행속도가 가장 큰 변화의 요인임을 알 수 있다.

4.2 인자별 가시도 예측

Fig. 9는 인공신경망에 의한 인자 변화별 가시도 예측치이다. 차량대수가 10~1,080 대/h로 증가하면 1,684~599 m로 감소한다. 주행속도는 0~180 km/h로 증가하면 가시도는 154~9,691 m로 증가하며, 외부풍속은 1~4 m/s로 증가하면 8,303~228 m로 감소한다. 구배가 -2~2%까지 증가하는 경우 가시도는 115~9,192 m로 증가하였다. 이러한 결과에서 가시도 역시 주행속도가 가장 큰 농도 변화 요인이라 판단되어진다.

5. 결론 및 논의

본 연구에서는 역전파 알고리즘을 기본으로한 인공신경망을 적용하여 도로 터널에서 발생하는 오염물질 농도 예측하였다. 이에 대한 연구 결과를 요약하면 다음과 같다.

- 1) 개발된 인공신경망은 종류식 환기 방식이 적용된 일방향 2차선 도로 터널의 오염물질 농도 예측이 가능하였다. 인공신경망은 실측된 데이터를 이용한 반복 학습을 통하여 1×10^{-8} 의 오차한도에 수렴하였다. 학습된 인공신경망을 이용한 예측치를 검증한 결과 오염물질 농도는 실측 분포 패턴을 따르고 있으며 약 95%의 정확도를 보였다.
- 2) CO 농도의 경우 매우 높은 정확성을 보이는 구간에서는 실측치 21.1 ppm일 때 인공신경망에 의한 예측치는 21.21 ppm을 보임으로써 약 0.05%의 매우 낮은 오차율을 보였으며, 가시도 역시 실측치 1,600 m일 때 인공신경망의 예측치 1,493 m로 약 6.7%의 오차율을 나타내었다.
- 3) 인공 신경망을 이용한 인자별 오염도 예측에서는 예상했던 바와 같이 CO 농도와 가시도 모두 가장 큰 영향을 미치는 인자는 주행 속도이다.
- 4) 학습된 인공 신경망과 PIARC 방식에 의한 계산치를 비교하면 CO 농도의 경우 인공신경망은 오차 범위가 2.6~59%를 보이는 반면 PIARC 방식은 5~1,310 %의 범위를 나타내었다. 또한 가시도의 경우도 학습된 인공신경망은 0.1~33%, PIARC 방식 26~82%를 보임으로써 인공신경망에 의한 예측치가 5배 이상의 정확도를 보였다. 즉, PIARC 방식에 대

한 적절한 수정 및 보완이 필요하리라 판단된다.

- 5) 현재 도로터널 환기 설계시 가장 큰 문제점은 차량의 오염물질 배출량 산정일 것이다. 본 연구는 개발된 인공신경망 현시점에서 대두되고 있는 차량 오염물질 배출량의 잘못으로 인하여 과대한 소요환기량이 산정되는 것을 보완하여 PIARC 방식을 개선할 수 있을 것이다. 인공신경망은 특성상 오염물질의 예측시 계수의 영향을 받지 않는 장점이 있으므로 적절한 인자 선정 및 보완, 그리고 지속적인 학습을 통한 인공지능의 개선은 신뢰도 높은 터널 오염물질 예측 시스템의 완성도를 높일 것이며, 나아가 종래의 터널 환기 설계 기법들의 실제와의 차이에 생길 수 있는 과설계를 방지하여 보다 효율적인 터널 환기 설계에 많은 기여를 할 것으로 기대 된다.


참고문헌

1. 김남영, 김효규, 2001, 장대터널 환기 설계 기준에 관한 기초 연구, 대한설비공학회 하계학술발표회 논문집, 774-778.
2. 김우동, 홍대희, 김태형, 이태원, 2000, 터널 환기를 위한 오염도 추정 알고리즘, 공기조화 냉동공학회, 2000하계학술발표회 논문집, 1392-1396.
3. 유지오, 남창호, 신현준, 2000, 젯팬 종류식 터널의 퍼지 응용 제어로직에 관한 연구, 설비공학논문집, 12.8.
4. 김우동, 홍대희, 김태형, 이태원, 터널 환기를 위한 오염도 추정 알고리즘, 공기조화 냉동공학회, 2000하계학술발표회 논문집, 1392-1396.
5. 이상원, 1998, 학습하는 기계 신경망, Ohm 사.
6. 이상용, 1998, 인공지능, 상조사.
7. 한국건설기술연구원, 2000, 도로형태에 따른 최적환기량 산정 및 단계 건설에 관한 연구(2단계).
8. D.O. Hebb, The Organization of Behavior, Wiley, New York, 1949.
9. D.E. Rumelhart, J.L. McCulloch, and the PDP Research Group, 1986, Parallel Distributed Processing, Vol. I, II, MIT Press.
10. G.E. Hinton, T.J. Sejnowski, and D.H. Ackley, May, 1984, Boltzmann machines: Constraint Satisfaction networks that learn, Carnegie Mellon Univ. Technical Report #CMU-CS-84-119, CMU.
11. James A. Freeman, David M. Skapura, 1992, Neural Network, Addison-Wesley Publishing Company.
12. KHC, 1997, Guidelines of Ventilation Facility Design in Highway Tunnels.
13. M.Minsky and S.Papert, 1969, Perceptrons, MIT Press.
14. P. D. Wasserman, 1993, advanced methods in neural computing, Van Nostrand Reinhold, New York.
15. R.P. Lippman, March, 1988, An Introduction to Computing

with Neural Nets, IEEE Computer, 21.3, 11-22.

16. Stephen T. Welstead, 1994, Neural network and fuzzy logic applications in C/C++, John wiley & sons, INC.

이 덕 준



2001년 인하대학교 자원공학과 공학사
2003년 인하대학교 자원공학과
공학석사

Tel: 032-860-7558
E-mail: djlee1118@orgio.net
현재 도담 E&C

유 용 호



1997년 인하대학교 자원공학과 공학사
1999년 인하대학교 자원공학과
공학석사

Tel: 032-860-7558
E-mail: ventil@hanmail.net
현재 인하대학교 자원공학과 박사과정

김 진



1987년 인하대학교 공학사
1990년 미국 University of Kentucky
공학석사
1995년 미국 University of
Missouri-Rolla 공학박사

Tel: 032-860-7558
E-mail: jtnkim@inha.ac.kr
현재 인하대학교 환경토목공학부 부교수
