

Neural Network Theory를 이용한 노면온도예측모형



양 충 현 | 정회원 · 한국건설기술연구원 도로연구실 수석연구원

1. 서론

최근 한반도는 지구온난화의 영향인 것으로 추정되는 기상이변에 따른 높은 강설량과 향후 지속적인 강설량 증가 가능성, 동절기 기온급감, 어는 비, 단시간 집중 폭설 등과 같은 자연재해 발생빈도가 증가하고 있다. 그림 1은 지난 3년간 전국에 발표된 대설주의보¹⁾ 및 대설경보²⁾ 자료를 나타내고 있다. 지역별 연도별 대설주의보 발생횟수는 강원도 지역에서 충청도와 전라도 지역으로 그 추세가 변화하는 경향을 보이고 있다. 흥미로운 점은 대설주의보의 경우, 2007년부터 2010년까지 발표횟수가 꾸준히 감소하는 반면, 같은 기간 대설경보는 오히려 증가하는 추세를 보이고 있다(기상청, 2010).

이는 향후 예기치 못한 폭설이 내릴 가능성이 높다는 것을 시사하고 있다. 이에 따라, 동절기 도로관리의 중요성은 더욱 강조될 수밖에 없다. 동절기 어는 비의 경우도 도로관리에 치명적인 어려움을 야기할

다. 실제로 동절기에 도로결빙으로 인한 미끄럼 교통사고가 증가하고 있는 실정이다. 지난 3년간 통계에 따르면, 노면적설상태에서 사고가 발생하여 42명이 사망하고 노면결빙상태에서 4,796건의 사고가 발생하여 총 215명이 사망한 것으로 나타났다(도로교통공단, 2009).

그림 2에서와 같이 노면적설상태에서의 교통사고 건수는 2006년에는 2003년과 2004년에 비해, 각각 6.7%, 8.8% 증가하였음을 알 수 있다. 노면상태에 따른 교통사고 유형별 치사율을 살펴보면 그림 3과 같다.

차량 단독 사고의 경우, 적설 시가 차대차 또는 차대사람 사고 유형보다 치사율이 높은 것으로 조사되었다. 차대차 사고로 인한 치사율은 노면결빙상태 일 때가 가장 높은 것으로 나타났다. 차대사람인 경우의 치사율은 노면이 건조할 때가 가장 높게 분석되었다.

그림 4에서 보면, 국가 주요 간선도로망(고속국도, 일반국도, 지방도)에서 도로적설이나 도로결빙으로 인한 치사율이 높게 나타나고 있음을 알 수 있다. 도로결빙이 발생하기 쉬운 노면결빙 취약구간 선정과 적절한 대처방안 수립은 동절기 도로관리 측면에서

1) 24시간 신적설이 5cm 이상 예상될 때

2) 일반지역에서는 강설량이 30cm 이상 예상될 때 발표(대도시 지역과 울릉도 지역에서는 각각 20cm, 50cm 이상 예상될 때)





그림 1. 2007년-2010년 지역별 대설주요부 및 대설경보 발령 횟수




그림 2. 노면적설상태에서의 교통사고 발생 건수




그림 3. 노면상태에 따른 교통사고 유형별 치사율 비교

매우 중요하다. 따라서 본 연구에서는 신경망 이론을 적용하여 초단시간 노면온도예측모형을 개발하고 이

를 청원-상주 고속도로의 문의교 구간에서 관측한 도로기상정보시스템 결과와 비교하여 검증하고자 한다.




그림 4. 도로종류별 노면상태별 치사율 비교

1.1 기존문헌 고찰

선진외국에서는 도로구간의 노면온도를 측정하고 관리하기 위해 비접촉식 노면온도측정 시스템 (Thermal Mapping)을 많이 이용하고 있다. 특히, 유럽에서는 이러한 시스템을 이용하여 노면온도지도 (Thermal Map)를 작성하고, 이를 바탕으로 제설작업의 우선순위를 결정하는 기초자료로 이용하고 있다.

그림 5는 오스트리아 비엔나 시에서 Thermal Mapping을 통해 작성한 노면온도지도를 나타낸다.



그림 5. 오스트리아의 제설작업 지도

미기상학분야에서 대기기상과 지표면 온도 사이의 관계를 규명하기 위한 노력이 많이 진행되어왔다. 박순웅(1994)은 지표면의 물리적 조건(토양과 식생 존재여부)이 대기경계층 성장에 미치는 영향에 대한

연구를 수행하였다. 또한, 최근 대기기상과 지표면 사이의 에너지수지방정식을 통한 지표면온도변화 추이를 분석하는 연구도 진행되었다(Song & Lee, 2002).

유럽, 일본, 미국, 캐나다 등에서는 이미 1990년대 초부터 노면온도 또는 노면결빙점 예측모형을 구축하고 검증한 연구가 진행되어 오고 있다. Sass (1997)는 덴마크 기상청(Danish Meteorological Institute)에서 추진하던 노면자동예측 시스템에 내재되는 Road Condition Model(RCM)을 개발하였다. 이 연구에서 예측모형의 민감도는 시스템에 입력되는 대기기상자료에 매우 의존하는 경향이 있다고 밝혀졌으며, 적어도 현 시점에서 3시간 후 범위까지는 매우 높은 예측 정확도를 보이는 것으로 판명되었다. Shao와 Lister(1996)의 모형에서는 정해진 도로구간에 대해 짧은 시간동안(일반적으로 3시간 후) 노면 온도와 상태에 대한 높은 예측 정확도를 가진 정보를 산출하기 위해 자동화된 도로결빙 예측 모형을 개발하였다. 모형의 타당성을 입증하기 위해 유럽 7개국 41개 도로 구간을 대상으로 도로표면에 설치된 노면온도측정 센서로부터 취득한 관측값과 모형을 통해 산출된 값을 비교하였다. 이 모형의 가장 큰 특징은 노면 온도예측이 요구되는 지점으로부터 수집한 풍속, 이슬점, 대기온도, 노면온도를 자동으로 수집하는 것 외에 다른 외부 기상자료 없이 노면온도를 예측할 수 있다는 점이다. 캐나다의 Louis-Philippe와 Delage(2001)는 캐나다 기상청의 의뢰를 받아 연구 목적으로 METRo시스템을 개발하였다. 이는 도로기상정보체계로부터 수집된 관측값과 캐나다 기상청 고유모형으로부터 예측된 기상자료를 사용할 수 있고, 노면 위의 액체 그리고 고체 상태로 된 수분누적 상태를 설명할 수 있는 장점이 있다.

Sato(2004)의 연구에서는 일본 산악지역 중 강설량이 많은 지역에 적용하기 위한 노면온도예측 모형을 개발하였다. 일반적으로 노면온도는 도로가 통과하는 지형 또는 지역마다 큰 차이를 보이고 있다. 이것은 주로 각 도로 구간의 환경요인들이 서로 다르고

그 지역에 유일하다는 사실에 근거 하고 있는데 노면 온도는 늦은 오전 정오에 최고점에 도달하고 해 뜨기 직전에 가장 낮은 점에 도달하나 바위가 높은 비율을 차지하고 있는 산과 같은 환경에서는 이러한 주간 온도 패턴과 다를 수 있음이 밝혀졌다. Fujimoto(2009)의 연구에서는 black-ice³⁾와 차량으로부터 발생하는 열과의 관계를 규명하기 위한 모형을 구축하였다. 연구결과, 차량으로부터 발생하는 열들은 도로의 결빙과 해빙에 영향을 미치고 이러한 현상들이 결과적으로 도로 상에 black-ice 현상을 유발하는 것으로 나타났다.

앞서 살펴본 바와 같이, 외국에서는 이미 오래전부터 노면온도와 상태를 예측하기 위한 연구가 진행되어져 왔고, 고유의 모형을 보유하고 있다. 그러나 국내에서는 아직 도로기상분야에서 이러한 연구는 미흡하며, 따라서 국내 노면온도예측 모형이 없는 실정이다.

2. 본론

본 연구에서는 신경망 이론의 적용을 통해 향후 1~3시간 후의 노면온도를 예측할 수 있는 모형을 개발하였고, 이를 청원-상주 고속도로의 문의교에서 관측한 도로기상정보시스템 자료를 이용하여 검증하였다.

2.1 모형 구축

“대기온도”는 가장 중요한 기상변수 중 하나이고, 대기온도변화추이에 대한 예측은 기상관련 학문분야에서 중요한 부분을 차지하고 있다. 지난 수십 년 간 신경망이론을 통한 대기온도의 정확한 예측을 위한 노력들이 기상모형분야 발전에 많은 기여를 한 것이 사실이다. 센서나 기상관측장비를 통한 현장 관측값에만 의존한 신경망 이론은 『physically-based』와

대조적으로 『data-driven』으로 고려될 수 있다. 신경망 이론을 기상분야에 성공적으로 적용한 결과, 적절하게 설계된 신경망 이론은 대기기상관측에서 누락된 또는 단절된 부분을 매우 잘 묘사하는 것으로 나타났다(Mihalakakou et al., 1998, Santamouris et al., 1999, Bodri and Cermak 2000, Luk et al., 2000, Bodri, 2001). 비록 대기온도변화는 무작위성(random-like) 같이 보이긴 하지만, 신경망 이론이 반복적인 기상 패턴의 특성을 매우 잘 나타낸다고 하는 것은 분명한 사실이다. 따라서 신경망 이론을 적용한 모형은 기상 예측 뿐만 아니라, 해양과 대기 순환 분야에도 널리 사용되고 있다.

본 연구에서는 도로교통분야에서 중요한 요소로 고려되는 노면온도예측을 위해 신경망 이론을 적용하였다. 관측된 노면온도, 대기온도, 대기습도 등을 바탕으로 향후 1~3시간 후의 노면온도를 예측하고자 하는 것이 큰 목적이다.

노면온도는 일반적으로 대기기온, 일사량, 구름의 양 및 형태, 풍속, 강수, 대기압 등의 변화 패턴과 같은 대기 기상 변수들과 노면의 경사 방향 및 경사도, 주변 장애물, 주변의 토지 이용도 등의 지리 변수, 도로의 종류, 색깔, 거칠기 길이, 연직 구조 등의 도로 공학 변수 및 교통량 등에 영향을 받는 것으로 연구되고 있다(Thornes and Shao, 1991). 따라서 물리적 과정을 통해 노면온도를 예측하기 위해서는 많은 양의 입력자료와 복잡한 수식이 요구된다. 이렇게 구성된 복잡한 수식이 반드시 정확한 결과를 도출해내는 것은 아니다.

이러한 문제점들을 줄이고, 보다 정확한 노면온도 예측을 위한 또 다른 접근법 중 하나는 통계적인 방법이다. 이러한 방법은 노면온도가 일반적으로 연주기 변동과 일주기 변동을 가진다는 특성을 이용하여 과거에 수집된 노면온도 자료를 통계적으로 분석하여 “통계적인 데이터베이스”를 구축하고, 이를 이용하여 장래 노면온도를 예측하는 방법이다.

이 방법에서는 일단 데이터베이스가 구축되고 나면, 나머지 값들은 모두 결정된다는 단점이 있다. 이

3) 도로결빙이 없는 것처럼 보이지만, 실제로 결빙이 되어 있는 상태

러한 단점을 보완하기 위해 신경망 모형이 적용되어 노면온도를 예측한다.

본 연구에서는 입력층(Input layer), 가운데 숨은 층(Hidden layer), 출력층(Output layer)의 3층 구조로 이루어진 신경망의 설계를 통해 특정 도로구간에 대한 향후 노면온도를 예측할 수 있는 모형을 개발하였다. 그림 6에서 N_1, N_2, N_3 각각은 입력층, 가운데 숨은 층, 출력층에 있는 뉴런의 수를 나타낸다(Shao, 1998).




그림 6. 신경망의 3가지 층 설계 개요

가운데 숨은 층과 출력층의 각 뉴런 j 의 가중합(Sum of weights)은 다음 식 (1)과 같이 표현이 가능하다.

$$Net_j = \sum_i w_{ij} out_i \quad (1)$$

여기서, out_i 는 그 전 층(layer)의 i 번째 뉴런을 나타내고 w_{ij} 는 그 전 층(layer)의 i 번째 뉴런에서 다음 층의 j 번째 뉴런으로 가는 가중치를 나타낸다.

각 뉴런 j 로부터의 출력(out_j)은 활성함수, 즉 아래 식 (2)와 같은 sigmoid 전달함수로 유도된다.

$$f(net_j) = \frac{1}{1 + \exp(-knet_j)} \quad (2)$$

여기서, $f(net_j)$ 은 0과 1사이에 놓여 있으며, k 는 함수의 확산과 관련된 양의 상수로 1.5를 사용하였다. 노면온도를 예측하기 전에 신경망은 이미 알고 있는 입력자료와 출력자료를 이용하여 훈련과정(training process)을 거친다.

우선, 입력자료는 첫 번째 층의 뉴런(neuron)으로 가고, 가운데 숨은 층 뉴런은 가중치에 비례하여 입력 뉴런으로부터 값을 받아들인 후 출력 뉴런을 위한 입력 뉴런이 된다. 출력 뉴런에서의 값과 실제 관측 값과의 오차는 뉴런들 사이의 가중치(weight)를 보정(adjust)하는데 사용된다. 출력값(out_j)과 관측 값(T_j) 사이의 오차를 다음 식 (3)과 같이 최소화하도록 가중치를 보정한다.

$$Err = \frac{1}{2} \sum_j (T_j - out_j)^2 \quad (3)$$

오차(Err)는 입력자료와 가중치의 함수로 이를 최소화하기 위한 가중치를 선택하는데, 이 과정의 학습을 backward propagation 법칙이라 한다(Beale and Jackson, 1994). 먼저 출력 뉴런에서 오차가 계산되고, 나중에 숨은 층으로 되돌아 온다. 이 과정에서 뉴런과 뉴런의 출력층 사이의 가중치가 변하게 된다. 그 결과 오차를 최대로 감소시키는 방향으로 신경망이 움직인다. 일반적인 가중치 조절은 식 (4)와 같이 표현된다.

$$w_{ij}(t+1) = w_{ij}(t) + \eta \delta_j out_i \quad (4)$$

여기서, η 는 학습률, δ_j 는 뉴런의 오차 항을 나타낸다. 출력 뉴런에 대한 오차 항은 $\delta_j = k out_j (1 - out_j) (T_j - out_j)$ 으로 표현된다. 가운데 숨은 층에 대해서는 $\delta_j = k out_j (1 - out_j) \sum_k \delta_k w_{jk}$ 으로 나타낼 수 있다. 처음에 숨은 층과 출력층 사이의 모든 연결의 가중치는 무작위(random) 또는 전시간(previous time step)의 마지막 값으로 정해진다.

학습률은 $\eta = 1 - \ln(1.2 + \frac{t}{t_{max}})$ 과 같이 시간의 함수로 간주된다. 여기서, t 는 반복 횟수, t_{max} 는 반복의 최대 횟수(본 연구에서는 5,000을 사용)를 각각 나타낸다. 학습과정(learning process)은 다음의 3가지 경우를 만족할 때 종료될 수 있다.

- (a) 오차가 0.1℃ 보다 작을 경우
- (b) 모든 가중치가 안정화 되는 경우(가중치의 변화 값 < 0.0001)
- (c) $t \geq t_{max}$ 인 경우

과거자료에 대해 성공적인 훈련을 완료한 후에 최근의 실시간 자료를 입력자료로 받아들여 훈련된 입력자료와 비교하여 가장 유사한 입력자료를 선택하여 본 연구에서 설계된 신경망을 통해 출력 결과를 생성한다.

입력자료 결정을 위해 노면온도에 영향을 미치는 요인에 대한 민감도 실험을 반드시 수행해야 한다. 그러나 일반적으로 모형 수행에 필요한 관측값이 제한되어 있다. 또한 설계된 신경망에 대한 효율적인 사용을 위해서는 관측값을 최대한 활용하는 방안을 마련해야한다. 일반적으로 대기환경 특성상 오차(error)는 주간에 크고, 야간에 작으며, 비선형적(non-linear)이며 지표면 근처의 2m 높이의 대기환경과 시간적 변화와 상관성이 매우 높다(Thornes and Shao, 1991).

표 1. 입력 뉴런과 출력 뉴런의 종류

No	입력 뉴런	수식기호
1	Time of Day	$\sin(\frac{2\pi t}{24h})$
2	Variation of surface temperature 1 hour earlier	$T_s^1 - T_s^2$
3	Variation of surface temperature 2 hour earlier	$T_s^2 - T_s^3$
4	Derivative of surface temperature variation	$(T_s^1 - T_s^2) - (T_s^2 - T_s^3)$
5	Variation of surface temperature 24 hour earlier	$T_s^{24} - T_s^{25}$
6	Variation of surface temperature 48 hour earlier	$T_s^{48} - T_s^{49}$
7	Variation of air temperature 1 hour earlier	$T_a^1 - T_a^2$
8	Variation of air temperature 2 hour earlier	$T_a^2 - T_a^3$
9	Derivative of air temperature variation	$(T_a^1 - T_a^2) - (T_a^2 - T_a^3)$
10	Variation of air temperature 24 hour earlier	$T_a^{24} - T_a^{25}$
11	Variation of air temperature 48 hour earlier	$T_a^{48} - T_a^{49}$
12	Variation of relative humidity 1 hour earlier	$RH_s^1 - RH_s^2$
13	Variation of relative humidity 2 hour earlier	$RH_s^2 - RH_s^3$

No	출력 뉴런	수식기호
1	Forecast error 1 hour earlier	$T_f^1 - T_s^1$
2	Forecast error 2 hour earlier	$T_f^2 - T_s^2$
3	Forecast error 3 hour earlier	$T_f^3 - T_s^3$

본 연구에서 신경망 수행을 위한 입력 자료로 2009년 10월 1일부터 2010년 2월 28일까지 청원-상주 간 고속도로 문의교 지점에서 30분 간격으로 관측된 노면온도, 대기습도, 상대습도를 사용하였다.

본 연구에서 설계한 신경망 활용에 필요한 입력 뉴런(Input Neuron)과 출력 뉴런(Output Neuron)을 표 1과 같이 나타내었다.

표 1에서와 같이 본 연구에서 구축한 신경망은 13개의 입력 뉴런(Input Neuron), 2개의 숨은 뉴런(Hidden Neuron), 3개의 출력 뉴런(Output Neuron)으로 구성되어 있다.

2.2 모형 검증

본 연구에서 개발된 모형을 실제 문의교 부근에서 겨울철 4개월 동안 수집한 노면온도, 대기온도, 대기 습도 자료를 통해 신경망 모형에 적용한 후, 모형 성능을 평가하기 위해 12월 1개월 간의 노면온도를 예측하고, 이를 접촉식 노면온도센서로부터 수집한 12월 1개월 간의 노면온도와 비교·검토하였다. 그림 7은 본 연구의 연구지점인 청원-상주 간 고속도로 문의교 부근에 설치되어 있는 접촉식 노면온도측정 센서와 도로변 기상관측장비(대기 온·습도 측정용), 그리고 한국도로공사 보은지사에서 운영하고 있는 모니터링 시스템에 대한 것을 나타내고 있다.


신경망 모형 성능을 평가하기 위해서 현재에서부터 1시간 후 예측, 2시간 후 예측, 그리고 3시간 후 예측 총 3가지에 대한 노면온도 예측을 수행하였고, 그림 8은 모형 수행결과 값(NN 1h, 2h, 3h)과 실제 관측값(OBS)을 비교한 결과이다.

신경망 모형에서 학습된 내용을 바탕으로 예측해 본 결과, 예측된 노면온도는 관측값의 변화경향을 잘




그림 7. 연구지점의 접촉식 노면온도측정 센서, 도로변 기상관측장비, 센터 전경


따라가는 것으로 나타났다. 보다 상세한 결과값을 검토하기 위해 12월 6일부터 9일까지의 모형 수행결과



(a) 1시간 후 노면온도 예측 결과



(b) 2시간 후 노면온도 예측 결과




(c) 3시간 후 노면온도 예측 결과

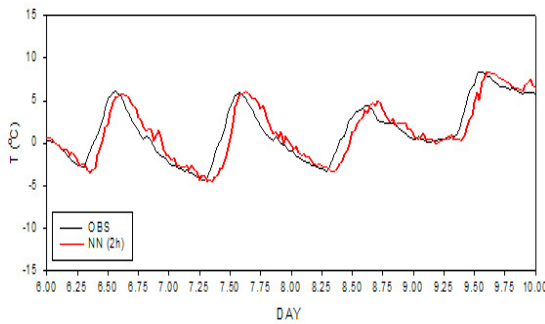
그림 8. 신경망을 이용한 모형 수행결과 값과 실제 관측값의 비교

값(NN 1h, 2h, 3h)과 실제 관측값(OBS)에 대한 상세한 시계열을 나타내면 그림 9와 같다.


그림 9에서 나타난 것과 같이 접촉식 노면온도 측정 센서로부터 취득한 노면온도 값과 신경망을 통해 산출된 예측값(1h, 2h, 3h 각각과 비교) 사이의 평균 오차는 일반적으로 타당하다고 허용되는 오차 $\pm 2^{\circ}\text{C}$



(a) 1시간 후 노면온도 예측 결과



(b) 2시간 후 노면온도 예측 결과



(c) 3시간 후 노면온도 예측 결과


그림 9. 2009년 12월 6일부터 9일까지의 상세 시계열

보다 적은 것으로 나타났다.


앞서 보인 결과에 대한 통계적 검증을 위해 신경망 모형을 통해 나온 결과값과 현장 관측값 사이의 관계를 나타내는 scatter plot을 실시하였다. 이는 plot을 통해 두 결과간의 관련성, 즉 직선과 곡선 등의 특별한 경향을 시각적으로 파악하기 위함이다. 그림 10은 모형 수행결과값(NN 1h, 2h, 3h)과 실제 관

측값(OBS) 사이의 관계를 나타낸 scatter diagram 결과를 나타낸다.


그림 10에서 나타난 것과 같이, 현장에서 접촉식 노면온도 센서를 통해 수집한 온도 값이 증가함에 따라 신경망 모형 수행을 통해 산출된 노면온도 모형 수행결과값 (NN 1h, 2h, 3h)이 커지는 경향이 있음을 알 수 있다. 즉, 이들 사이에는 양의 선형관계가



(a) 1시간 후 노면온도 예측 결과



(b) 2시간 후 노면온도 예측 결과



(c) 3시간 후 노면온도 예측 결과

그림 10. scatter diagram 결과

있으며, 편차의 평균값은 거의 0에 가까운 값을 보였다. 편차의 표준편차는 1시간 예측인 경우 0.55℃, 2시간 예측인 경우 1.27℃, 그리고, 3시간 예측인 경우 1.43℃를 보여 매우 정확한 예측을 수행하였음을 알 수 있다. 상관계수 R^2 값 역시 1시간 예측인 경우 0.985, 2시간 예측인 경우 0.923, 3시간 예측인 경우 0.903으로 매우 정확하게 예측되었음을 알 수 있다.

3. 결론

현재 국내에서는 고속도로와 일반국도 일부 구간에서 노면센서와 도로변 기상관측 장비 등을 통해 도로변 기상상황에 대한 자료를 수집하고 있고 이를 바탕으로 도로관리업무를 수행하고 있다. 그러나 아직까지 노면온도예측을 위한 모형 또는 소프트웨어 대부분을 외국에서 개발된 것에 의존하고 있는 실정이다. 이로 인해 실제 노면온도예측을 포함한 운영상의 문제가 발생해도 모형에 내재되어 있는 정확한 알고리즘에 대한 정보가 없어 국내 지형 및 도로교통조건에 따른 모형의 보정이나 수정이 쉽지 않는 것이 사실이다. 이러한 문제점들을 해결하기 위한 기초연구로써, 본 연구에서는 일반적으로 기상분야에서 많이 사용되고 있는 신경망 이론을 적용하여 신경망을 설계하고, 국내 도로에서 실제로 측정된 노면온도, 대기온도, 대기습도 자료를 통해 현재시점에서부터 1~3시간 후의 노면온도의 변화에 대한 예측을 수행하고 검증하였다.

본 연구에서는 13개의 입력 뉴런을 설정하였으며, 2개의 숨은 뉴런을 사용하여 향후 1시간, 2시간, 그리고 3시간 후의 노면온도를 예측하였다. 예측된 노면온도와 실제 관측한 노면온도에 대한 편차에 대한 표준편차가 1시간 예측인 경우 0.55℃, 2시간 예측인 경우 1.27℃, 그리고, 3시간 예측인 경우 1.43℃를 보였으며, 예측된 노면온도를 실제 관측한 자료와 비교한 결과 R^2 값이 각각 0.985, 0.923, 0.903으로 매우 정확하게 나와 모형의 설명력이 높은 것으로 판

단된다.

본 연구에서 개발된 모형은 실제 도로에서 설치된 도로기상정보시스템에서 측정된 기상 및 노면온도 자료를 이용하여 그 지점의 향후 노면온도를 예측하는데 활용이 가능할 것으로 판단된다. 그러나 모형의 현장 적용 성을 높이기 위해서는 향후 관측 값과 예측 값 사이의 오차(error)를 최소화하기 위해 필요한 적정 자료의 길이, 입력 변수의 재설정, 숨은 뉴런의 개수 산정 등에 대한 조사가 필요하다. 계절이나 기상 조건에 따른 가중치의 재설정 여부 등에 대한 추가 조사가 필요할 것으로 판단된다.

향후 주요 간선도로망의 노면온도에 대한 정확한 예측이 가능하게 된다면, 도로관리자 입장에서는 제설작업의 시점 및 작업정도와 같은 의사결정 지원은 물론, 도로의 결빙취약구간 선정과 노면온도지도(Thermal Map) 작성을 통해 도로구간별 제설작업의 우선순위를 선정하는데 매우 유용하게 사용될 것으로 판단된다.

참고 문헌

1. Beale, R. & T. Jackson, (1994). "Neural Computing: An Introduction". Institute of Physics Publishing, pp 240.
2. Thornes, J. E. & Shao, J. (1991). "A comparison of UK ice prediction models". Meteorological Magazine 120: pp 51-57.
3. Shao, J. (1998). "Improving nowcasts of road surface temperature by a backpropagation neural network". Weather and Forecasting 13: pp 164-171.
4. Bodri L., (2001). "Precipitation prediction with neural networks". Acta Geod. Geoph. Hung., 36, pp 207-216
5. Bodri L. and CCermaak V., (2000). "Prediction of extreme precipitation using a neural network, application to summer flood occurrence in Moravia". Adv. Eng. Soft., 31, pp 311-321.

6. Luk K.C., Ball J.E. and Sharma A., (2000). "A study of optimal model lag and spatial inputs to artificial neural network for rainfall forecasting". J. Hydrol., 227, pp 56-65.
7. Mihalakakou G., Santamouris M. and Asimakopoulos D., (1998). "Modeling ambient air temperature time series using neural networks". J. Geophys. Res. 103, pp 19,509-19,517.
8. Sass, B.H. (1997), "A Numerical Forecasting System for the Prediction of Slippery Roads". Journal of Applied Meteorology. Vol.36, pp 801-817.
9. Shao and Lister (1996), "An Automated Nowcasting Model of Road Surface Temperature and State for Winter Road Maintenance". Journal of Applied Meteorology. Vol. 35. pp 1352-1361.
10. Crevier and Delage.(2002), "METro: A New Model for Road-Condition Forecasting in Canada". Journal of Applied Meteorology. Vol. 41 pp1226-1240.
11. Sato,(2009)"Road Surface Temperature Forecasting(Case Study in a Mountainous Region of Japan)",Proceedings of Cold Region Technology Conference, pp 382-388.
12. Fujimoto, Watanabe, and Fukuhara (2009). "Influence of Vehicle Related Heats on 'Black-ice'" 13th Road Engineering Association of Asia and Australasia Conference.
13. 박순웅(1994), "지표 물리적 조건이 대기경계층 성장에 미치는 영향", 한국기상학회 Vol. 30, No. 1.
14. 기상청(2010), "대설주의보 및 대설경보 발령횟수.pdf"
15. 도로교통공단(2010), "ROTA Webzine".
16. 한국건설기술연구원, (2009) "고속도로기상정보체계 구축 연구 1차년도 최종보고서", 한국도로공사
17. Song and Lee(2002), "Prognosis of the Road Surface Condition in Korea using Surface Energy Balance Theory", Journal of Korean Meteorological Society. Vol.1. No.2. 420-422.

학회지 광고접수 안내

본 학회지에 게재할 광고를 모집합니다. 우리 학회지는 계간으로 매회 2,100부를 발간하여 회원과 건설관련 기관에 배포하고 있습니다. 회사 영업신장과 이미지 제고를 원하시는 업체는 우리 학회지를 이용하시기 바랍니다.

광고료 : 표2 · 표3 · 표4(300만원) · 간 지(200만원)

※ 상기금액은 연간(4회)광고료임.

사단법인 **한국도로학회**

전화 (02) 3272-1992 전송 (02) 3272-1994