

토사재해 예경보를 위한 초단기 예측강우의 활용에 대한 연구

전환돈·김수전*[†]

서울과학기술대학교 건설시스템공학과

*인하대학교 토목공학과

A Study on Application of Very Short-range-forecast Rainfall for the Early Warning of Mud-debris Flows

Hwandon Jun·Soojun Kim*[†]

Department of Civil Engineering, Seoul National University of Science and Technology, Korea

*Department of Civil Engineering, Inha university, Korea

(Received : 31 July 2017, Revised: 21 August 2017, Accepted: 23 August 2017)

요약

본 연구의 목적은 토사재해 예경보를 위하여 초단기 예측강우의 적용성을 검토하는 것이다. 초단기 예측자료를 활용하기 위한 방법으로 신경망 모형을 적용하였다. 여기에서 레이더와 AWS의 관계를 이용하여 신경망을 학습하고 레이더 강우를 초단기 예측강우(MAPLE)로 대체하여 대상지역에 대한 강우량을 예측하였다. 6hr, 12hr, 24hr의 누적강우에 대한 토사재해 예경보기준을 이용하여 MAPLE 예측강우의 적용성을 Test-bed 지점에 설치한 AWS 강우량과 비교 평가하였다. 평가결과 MAPLE 예측강우를 이용할 경우 AWS를 이용할 경우 보다 선행하여 토사재해 예경보를 발령할 수 있음을 확인하였다.

핵심용어 : 토사재해, 예경보, 초단기 예측강우, 인공신경망

Abstract

The objective of this study is to explore the applicability of very short-range-forecast rainfall for the early warning of mud-debris flows. An artificial neural network was applied to use the very short-range-forecast rainfall data. The neural network is learned by using the relationship between the radar and the AWS, and forecasted rainfall is estimated by replacing the radar rainfall with the MAPLE data as the very short-range-forecast rainfall data. The applicability of forecasted rainfall by the MAPLE was compared with the AWS rainfall at the test-bed using the rainfall criteria for cumulative rainfall of 6hr, 12hr, and 24hr respectively. As a result, it was confirmed that forecasted rainfall using the MAPLE can be issued prior to the AWS warning.

Key words : Mud-debris Flow, Early Warning, Very Short-range-forecast Rainfall, ANN

1. 서 론

우리나라 국토의 대부분은 산지로 이루어져 있다. 산림청 통계에 따르면 2015년 기준으로 약 63.2%는 산지지역(2015년 기준, www.forest.go.kr)으로 1960년대 이후 산업화와 도시화와 함께 산림면적은 지속적으로 감소하여 왔다. 특히 무분별한 산지 개발로 인하여 곳곳에 대규모 절개지가 많이 존재하고 있으며 도심지내 또는 그 인근 지역에 위치하고 있는 급경사지는 토사재해의 위험을 가중하고 있다. 특히 2011년 7월 중부지방을 중심으로 시작한 집중호우는

우면산 지역에 대규모 토사재해를 유발한 바 있으며 이로 인해 18명의 사망자와 부상자 50명을 포함하여 700 억원대의 물적 피해가 발생한 사례가 있다.

이에 따라 우리나라에서도 토사재해에 대한 관심과 함께 많은 연구가 있어 왔다. Kim et al. (2011)은 경남지역 산사태 발생지의 강우 및 지형특성을 분석하여 산사태를 유발하는 한계강우량을 추정하였고 Lee et al. (2012)은 산사태 발생 강우량 임계치 1일 202 mm 및 3일 누적 449 mm로 적용하여 강원도 인제 덕적리 지역의 산사태 취약성도 및 미래 위험도를 작성 및 검증하였다. Ham and Hwang (2014)은 단시간 기록적인 폭우로 인한 산사태 및 복합호우로 인한 산사태 등을 모두 고려하기 위해서는 기존의 1일 강우량 기준은 다소 미흡한 점이 있으며 특히 호우양상이 복합호우 형태를 가지는 경우 연속강우량 기준으로 판

[†] To whom correspondence should be addressed.
Department of Civil Engineering, Inha university, Korea
E-mail: sk325@inha.ac.kr

단하는 것이 보다 효과적임을 제시하였다. Oh and Park (2014)은 강우를 활용한 산사태 위험예측은 강우관측소의 밀집도에 따라 신뢰성이 크게 좌우되며, 강우를 활용한 위험성 분석은 산사태 발생 시간의 예측에 더욱 큰 의미가 있음을 제시하였다. 이와 같이 기존 연구는 산사태의 위험도를 평가하기 위한 기준을 설정하기 위한 연구가 주를 이루었다. 최근에는 Son et al. (2015)은 초생대를 이용하여 산지유역의 토사유출을 저감하기 위한 방법론을 연구하였고 Lee et al. (2016)은 토사재해 발생시 인적피해를 유발하는 한계수심 및 한계유속을 산정하기 위한 연구를 수행하는 등, 토사재해 연구가 다양한 영역으로 확장되고 있다.

여기에서 선행 토사재해 연구의 한계는 우선적으로 토사재해의 발생에 가장 큰 영향을 미치는 강우량을 정량적으로 추정할 수 없다는데서 시작한다. 따라서 토사재해 연구 분야에서 강우량을 보다 정량적으로 평가하기 위한 연구도 함께 수행되어 왔다. Choi et al. (2013)는 강우의 공간적 분포 특성을 파악하는데 장점이 있는 레이더 영상을 산사태 예측을 위하여 적용하여 실험분석하였다. Jun et al. (2016)은 토사재해의 유발강우 산정시 레이더 강우를 활용하기 위한 연구를 수행하였는데 강우에 대한 미세측 지역이라고 할 수 있는 토사재해 위험지역의 강우추정(또는 관측)을 위하여 레이더 강우가 효과적으로 활용될 수 있음을 제시한 바 있다. 미국에서는 토사재해 예정보를 위하여 레이더 영상과 함께 지점강우관측소의 강우량을 적극적으로 활용(NOAA and USGS, 2005)하고 있다. 특히 유럽연합(EU, 2011)에서는 위성영상 및 기후모형(GCM)의 모의자료를 활용하여 토사재해의 발생을 예측하고 있다.

우리나라의 경우도 기상예측기술의 발달과 더불어 기상청을 중심으로 적극적으로 예측업무를 수행하고 있으며 초단기 강우예측을 위하여 일본 기상청의 현업 모형인 VSRF 모형을 활용하여 6시간 강수를 예측하고 있다. 이 외에도 미국 기상청, 국립호우연구소와 국립대기연구센터에서 공동 개발한 SCAN 모형, 미국 NCAR(US National Center for Atmospheric Research)에서 개발한 VDRAS(Variational Doppler Radar, Assimilation System) 모형과 캐나다 맥길대학교 개발한 MAPLE(McGill Algorithm for Precipitation nowcasting and Lagrangian Extrapolation) 모형에 대한 검토 및 시험운영을 하여왔다(Kim et al., 2009). Turner and Zawadzki (2004)은 레이더 영상을 이용하여 강수예측을 수행하는 MAPLE의 적용성을 검토한 바 있으며 Mandapaka et al. (2012)는 MAPLE을 이용한 강수의 선행예측은 3시간 이내로 한정하는 것이 타당함을 제시하였다. 최근에는 강수의 산악현상을 모형에 반영하기 위한 노력도 수행되고 있다(Sideris et al., 2015). 이러한 초단기 예측강우는 우리나라에서 단시간에 대한 기상예보, 돌발홍수 예정보를 위하여 활용되고 있다. 하지만 단기 강우예측에 대한 훌륭한 적용성에도 불구하고 아직까지 토사재해의 예측을 위하여 초단기 예측강우를 활용한 사례는 없었던 것이 사실이다. 따라서 본 연구에서는 토사재

해 예정보를 위하여 초단기 예측강우가 적용될 수 있는지에 대하여 검토하고자 한다.

2. 자료 및 방법론

본 연구에서는 토사재해 예정보에 있어 강우량 자료를 적극 활용하는 방법론을 제시하고자 한다. 이를 위하여 관측자료라고 할 수 있는 지상관측강우, 레이더강우와 함께 예측자료인 초단기 예측강우를 수집하였다. 여기에서 원시 레이더 강우와 지상관측강우와의 관계를 이용하여 신경망 모형을 학습하고 원시 초단기 예측강우를 입력자료로 적용하여 강수를 예측하였다. 그리고 시간단위 누가강우를 이용하는 토사재해 예정보 기준에 따른 예측강우의 적용성을 확인하는 방법론을 설정하였다.

2.1 레이더 강우와 보정기법

전통적인 강우량의 측정 방식은 우량계를 이용하여 지표면에 도달한 강우를 측정하는 것이다. 이러한 지점 우량 자료는 우량계 위치에 따라서 연속적으로 강우량을 지상에서 관측한다는 장점이 있다. 그러나 공간적으로는 불연속적이고 우량계 네트워크에서 실시간 자료를 복구하는 데에 많은 시간이 요구된다. 따라서 최근에는 레이더 강우와 같은 첨단영상에 의한 자료의 활용성이 극대화 되고 있다. 강우 레이더 관측 자료는 측정할 수 있는 지역 범위가 연속적이므로 특정 지역으로의 활용이 가능하다. 여기에서 강우 레이더는 강우량을 직접 측정하는 것이 아니라, 반사도를 측정 후 Z-R 관계식에 의해서 강우량을 추정한다(Wilson and Brandes, 1979). 따라서 왜곡된 강우량이 산정될 수 있다는 단점이 있다. 그러므로 지상 강우관측망과 강우레이더의 관측망을 합성하여 지상강우에 의해 보정된 레이더 강우 추정치(gauge adjusted radar rainfall estimate)를 이용해야 한다. 지상강우에 의한 보정(gauge adjustment)은 레이더 강우 추정치(radar rainfall estimate)의 정확성을 향상시키기 위해 널리 이용되고 있는 방법이다(Kim et al., 2007). 레이더 강우의 보정 방법은 G/R(Gauge to Radar)기법(Barbosa, 1994), Kalman-Filter 보정기법(Ahnert et al, 1986), 신경망에 의한 보정기법(Liu and Chandrasekar, 2001) 등이 대표적으로 활용되고 있다. 본 연구에서는 미세측 지점의 강우를 추정하기 위하여 레이더 강우와 주변 지상강우를 통합적으로 활용할 수 있을 뿐만 아니라 확장성과 적용성이 우수한 신경망에 의한 보정기법을 활용하였다.

2.2 신경망 기법과 오차역전파 알고리즘

퍼셉트론(perceptron)은 미국의 Rosenblatt (1958)가 패턴을 분류하기 위하여 제안했던 신경망 모형으로 하나의 뉴런, 즉 처리소자를 의미하며 후에 다층퍼셉트론(multi-layer perceptron)으로 발전하였다. 다층퍼셉트론은 여러

개의 처리소자를 각 계층에 모형을 구성한 것으로서 입력 자료를 받아들이는 입력층(input layer), 결과를 나타내는 출력층(output layer)으로 구성되며 두 개의 층 사이에는 중간층(hidden layer)을 두어 각 패턴마다 필요한 정보를 학습시킬 수 있도록 한 것이다. 입력층은 대상패턴인 각 입력값을 입력층과 중간층간의 연결강도를 곱해서 중간층으로 전달한다. 중간층은 입력층으로부터 받은 값들을 모두 합하여 전달함수를 통하여 출력하게 되고 이 값들은 다시 중간층과 출력층 사이의 결합강도와 곱해 출력층으로 보내진다.

오차역전파 알고리즘(error back propagation algorithm)은 다층퍼셉트론에서 입력패턴과 출력패턴에 대하여 오차를 줄여가는 과정, 즉 학습(learning)과정이다. 실제값과 계산값과의 차이를 역으로 진행시키면서 오차가 최소가 되도록 층과 층사이의 연결강도를 변화, 조절해 나가는 역방향처리(feedback)이다. 이러한 학습규칙은 결국 오차를 최소화하기 위한 규칙이므로 연결강도와 오차공간에서의 오차를 최소로 하여 연결강도를 구하는 최급강하법이 된다. 입력층, 중간층 그리고 출력층에서 각 연결강도의 계산은 다음과 같은 과정으로 진행된다. 신경망의 목적함수를 제곱오차라고 하는 경우, 이것은 출력층에서 출력되는 값 O 와 실제값 Y 와의 제곱오차의 합으로 표시되는 오차함수로 식 (1) 또는 식 (2)와 같이 표현할 수 있다(Kim et al., 2011).

$$E_p = \frac{1}{2} \sum_k (Y_{pk} - O_{pk})^2 \tag{1}$$

$$E_t = \sum_p E_p \tag{2}$$

여기서, p 는 다층퍼셉트론의 패턴번호, Y_{pk} 를 p 번째 입력패턴에 대한 k 번째 처리소자의 실측값, O_{pk} 를 p 번째 입력패턴에 대한 출력층의 k 번째 처리소자의 출력값, E_p 는 p 에 대한 오차, E_t 는 모든 패턴에 대한 총오차이다.

오차함수 E_t 가 0에 접근할수록 더욱 적절한 신경망이 완성되는 것이며, 역전파 알고리즘에서는 이를 위하여 경사하강(gradient descent) 알고리즘을 이용한다. 경사하강 알고리즘은 오차함수의 최소화를 위하여 가장 널리 쓰이는 방법으로써 오차 함수의 경사(gradient)에 비례하여 변수를 조절해 나가게 된다.

2.3 MAPLE(McGill Algorithm for Precipitation nowcasting and Lagrangian Extrapolation)

캐나다 맥길대학교에서 개발한 강수예측알고리즘의 MAPLE은 현재와 과거시간의 레이더 영상 차이를 통하여 강수예측의 이동벡터를 산출하는 변분예측 추적기법을 이용하고 있으며 라그랑지 연속성(Lagrangian persistence)에 기반을 두고 수 시간 이내의 강수 예측 위치에 대한 예측 정보를 제공한다(Kim, et al., 2009). 여기서 변분예측 추적기법(Variational Echo Tracking, VET)은 레이더 강수의 예코뿐만 아니라 위성 영상 등 시간에 따라 이동하는 모든 영상에 적용할 수 있다. 또한, 강수 예측 위치에 대한 예측 정보를 제공하는 라그랑지 연속성은 현재까지 강우패턴의 단기에측을 위한 최적의 방법으로 알려져 있으며 0~6시간 범위에 대한 수치모델의 기술은 다른 방법을 적용한 실험 예보보다 더 좋은 결과를 보이는 것으로 나타났다(Ministry of Construction and Transportation, 2007).

현재, 기상청에서는 강수장에서 CMAX, CAPPI, MERGE를 제공하고 있다. 여기서, PPI는 임의의 고도에서 수평방향으로 스캔하여 수신된 예코자료로 수평관측결과이며 CAPPI는 PPI(Volume 관측)에 대하여 일정한 고도(1.5km)의 수평자료를 추출한 자료를 의미한다. CMAX는 PPI자료의 각 고도에서 가장 강한 예코만 표출한 자료, RAR은 관측강우와 보정된 CAPPI 자료이며 BASE는 가장 낮은 고도에서의 예코가 나타난 최하층에 대한 자료로 1.5km에서 나타나지 않는 자료를 표출할 수 있다. MERGE는 CAPPI, CMAX, BASE와 AC_PPI 4개의 레이더 반사도값을 평균한 자료이다(Zawadski et al., 2007). 본 연구에서는 1km 공간해상도를 갖는 10분 단위 CAPPI 자료를 이용하였다.

2.4 토사재해 예경보 기준

Kim et al. (2016)은 Safeland (2012)의 토사재해 발생확률에 따른 4단계의 강우기준을 이용하여 우리나라에 적용이 가능한 강우 기준을 Table 1과 같이 제시한 바 있다. Table 1에서는 6시간, 12시간, 24시간의 누적강우에 해당하는 위험수준별 강우기준에 대한 정의를 나타낸다. None은 5% 강우기준 아래에 위치할 때이고, Watch는 5% 이상 20% 이하의 강우기준, Warning은 20% 이상 50%이하의 강우기준 그리고 Alarm은 50% 이상의 강우기준일 때로 정의된다.

Table 1. Rainfall criteria for the early warning of mud-debris flows (Kim et al., 2016)

Classification	Criteria	Cumulative rainfall(mm)		
		6hr	12hr	24hr
Null	Below 5% rainfall(0-5%)	-	-	-
Watch	Above 5% rainfall threshold & Below 20% rainfall threshold(5-20%)	52.98	73.90	103.07
Warning	Above 20% rainfall threshold & Below 50% rainfall threshold(20-50%)	82.91	109.40	144.36
Alarm	Above 50% rainfall threshold(>50%)	127.60	158.19	196.11

3. 적용 및 결과

3.1 대상지역

본 연구에서는 토사재해 연구를 위하여 금강유역 내에 금강과 미호천 합류부 근처에 위치한 세종특별자치시(구 주소: 충청남도 연기군 남면 진의리 산 64번지, TM coordinate system, 36.507642, 127.272202)을 대상지역(Test-bed)으로 설정하였다(Fig. 1 참고). 이 지점은 토사재해 모니터링을 위하여 자동우량관측장비를 설치/운영 중에 있어 지상에 발생한 강우량의 관측이 용이하다. 그리고 주변에 가까운 기상청 AWS로는 약 1.64km 거리에 있는 연기관측소와 약 5.48km 거리에 있는 금남관측소 등 연서, 공주, 정안 AWS 관측소들이 위치하고 있다(Table 2 참고). 따라서 주변관측소의 정보를 쉽게 활용하여 신경망 모형을 구성하고 그 결과를 비교 평가할 수 있다.

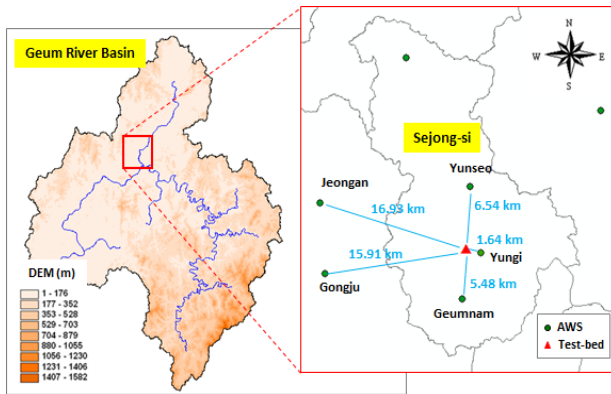


Fig. 1. Study area (TM coordinate system, 36.507642, 127.272202).

Table 2. AWS around the test-bed

AWS Code	Name	Distance (km)	TM_X	TM_Y
496	Geumnam	5.48	328972.4522	223833.0274
611	Yeonseo	6.54	340958.5677	224775.5303
612	Gongju	15.91	331695.6794	208700.9958
633	Jeongan	16.93	339218.0111	208138.3750
887	Yungji	1.64	333935.7580	225940.8770

3.2 강우자료

대상지역(Fig. 1)에 설치한 자동우량계로부터 2016년 주요 강우사상을 검토하였다. 이 중 2016년 일최고 강우량은 약 158.5mm로 7월 4일에 관측되었다. 따라서 7월 4일의 10분 단위 강우량을 수집하였으며 강우는 7/4/00:00 - 7/4/12:00 사이에 집중된 것을 확인하였다(Fig. 2 참고). 10분 최대 강우량은 8.5mm 였으며, 최대강우강도는 32mm/hr로 분석되었다. 그리고 대상지역 주변의 5개 AWS(금남, 연서, 공주, 정안, 연기)에 대한 강우량도 수집하였다(Fig. 1과 Table 2 참고).

기상청에서 운영 중인 기상레이더 중 대상지역과 가장 가

까이에 위치(직선거리 약 71km)하고 있는 관측소는 오성산 레이더 관측소이다. S밴드를 이용하는 오성산 관측소는 전라북도 군산시 오성산(위도 : 36.0105°, 경도 : 126.7867°)에 위치하고 있으며 2007년 5월에 설치되었다. 관측반경은 200 km로 우리나라 강원도, 경상북도 일부




Fig. 2. 10-minute rainfall at the test-bed

지역과 제주도 지역을 제외한 대부분의 지역이 관측반경에 포함된다. 시간해상도는 10분이며 공간해상도는 1km x 1km 시공간 해상도가 우수하다. 따라서 7월 4일 00시-12시 까지 10분 간격의 레이더 강우를 오성산 관측소로부터 수집하다. Fig. 3은 3시간 간격으로 표현된 레이더 강우 영상으로 당시에 강우의 띠가 8시에서 2시 방향으로 이동하면서 대상지역에 집중적으로 강우를 유발한 것으로 나타났다.

본 연구에서는 기상청에서 제공되는 초단기 예측강우 중 MAPLE 모형으로부터 생산되는 자료를 이용하였다. 이 자료는 10분 단위로 갱신되고 6시간 선행 예측과 10분 간격의 관측을 실시한다. 이들의 단일 격자 크기는 1km×1km이며, 예보 영역 1,024km×1,024km의 격자체계를 갖추고 있다(National Institute of Meteorological Science, 2009). 따라서 MAPLE 자료도 7월 4일 00시-12시 까지 10분 간격의 예측자료를 수집하였다. 이 중 7월 4일 03시와 06시를 기준으로 예측을 수행한 결과는 Fig. 4와 같다. 최초 예측 시작 시점은 Nowcasting 자료라고 할 수 있으며 1시간 간격으로 3시간까지 선행 예측한 자료는 Forecasting 자료라고 할 수 있다.

3.3 강우 자료의 보정 및 예측

초단기 예측강우 MAPLE 자료는 합성된 레이더 강우를 초기강우로 예측을 수행하는 방법이다. 따라서 레이더 강우와 마찬가지로 강우 자료의 보정이 필요하다. 본 연구에서는 이를 위하여 신경망을 이용하였으며 기본적인 적용 방법론과 결과에 대한 검증은 Jun et al.(2016)의 연구를 참고할 수 있다. 적용 방법을 간략히 도식적으로 표현하면 Fig. 5와 같다. 공간적으로 일치하는 지점 관측 AWS 지점에 격자 기반의 레이더 강우를 활용하여 신경망을 학습시킨 후 레이더 강우를 MAPLE 강우로 대체하여 목표지점(Test-bed)에 대한 예측을 수행하였다.

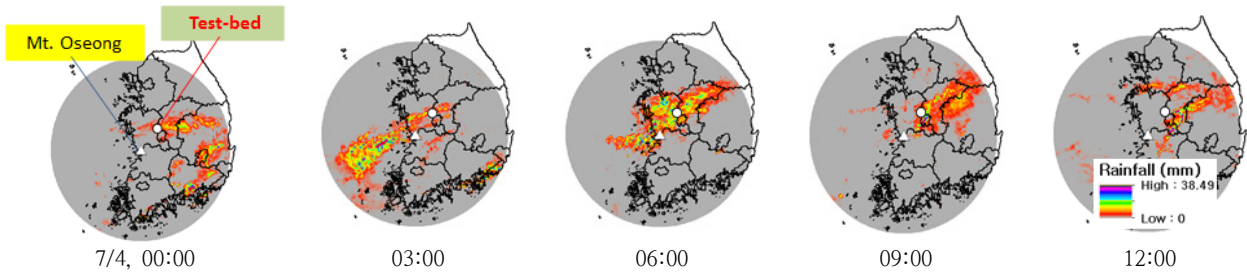


Fig. 3. Radar rainfall observed from Mt. Oseong station on July 4th, 2016.

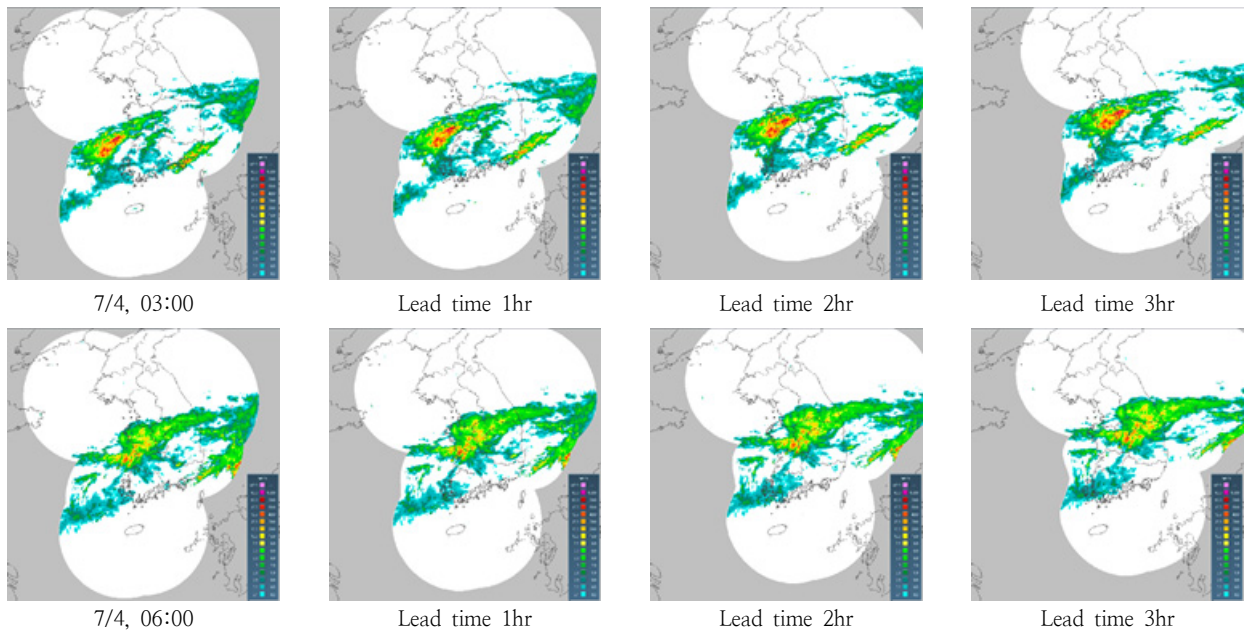


Fig. 4. MAPLE rainfall data on July 4th, 2016.




Fig. 5. Application method of Artificial Neural Network (ANN)

레이더 및 초단기 예측자료의 활용을 위한 세부 모형의 구성 방법은 다음과 같다. 우선 신경망의 학습을 위하여 입력자료로 지체시간(10분 단위)을 고려한 3개의 레이더 강우 $Radar_{k-2}$, $Radar_{k-1}$, $Radar_k$ 를 구성하였다. Kim (1993)은 신경망의 중간층 처리소자는 입력층의 개수가 D 개일 때 2D 또는 2D+1개로 구성할 것을 제안한 바 있다. 따라서 본 연구에서는 Kim (1993)의 연구를 바탕으로 4개의 노드로 구성된 중간층을 구성하였다. 그리고 AWS_k 를 목표로 설정하여 1개의 노드로 구성된 출력층을 하는 총 8개의 노드를 갖는 다층 신경망 모형을 구축하였다. 예측을 위하여 $Radar_{k-2}$, $Radar_{k-1}$, $Radar_k$ 대신에 초단기 예측

강우자료 $MAPLE_{k-2}$, $MAPLE_{k-1}$, $MAPLE_k$ 를 설정함으로써 대상지역(Test-bed)의 강우량을 예측하였다.

학습 및 예측결과는 RMSE (Root Mean Square Error), 상관계수(Correlation Coefficient, CC), 모형 효율성계수(Model Efficiency coefficient, ME, Nash and Sutcliffe, 1970)로 평가하였으며 각각 식 (3)-(5)와 같이 표현된다.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n [P_{obs}(i) - P_{sim}(i)]^2} \tag{3}$$

$$CC = \frac{\sum_{i=1}^n (P_{obs}(i) - P_{obs,ave})(P_{sim}(i) - P_{sim,ave})}{\sqrt{\sum_{i=1}^n (P_{obs}(i) - P_{obs,ave})^2} \sqrt{\sum_{i=1}^n (P_{sim}(i) - P_{sim,ave})^2}} \tag{4}$$

$$ME = 1 - \frac{F^2}{F_0^2}, \quad F_0^2 = \frac{1}{N} \sum_{i=1}^N [P_{obs}(i) - P_{obs,ave}]^2, \tag{5}$$

$$F^2 = \frac{1}{N} \sum_{i=1}^N [P_{obs}(i) - P_{sim}(i)]^2$$

여기에서, n 은 자료수, P_{obs} 는 관측 강우량, P_{sim} 는 모의 강우량, $P_{obs}(i)$ 는 시간 i 에서 관측 강우량, $P_{sim}(i)$ 는 시간 i 에 대한 모의 강우량, $P_{obs,ave}$ 및 $P_{sim,ave}$ 는 각각 n 개 자료에 대한 P_{obs} 및 P_{sim} 의 평균이다.

신경망을 이용한 모형의 평가 결과는 Fig. 6와 Table 3와 같다. 모형을 이용하여 예측을 수행하기 전에 레이더와 AWS와의 관계를 이용하여 학습한 신경망 모형의 검증은 위하여 Test-bed 지점에 대한 평가를 수행하였다. 검증 결과는 RMSE 3.15mm, CC 0.93, ME 0.81로 모형의 적용성이 우수한 것으로 판단되었다. 다음으로 모형의 예측 결과에 대한 검증을 위하여 신경망 모형에 MAPLE 자료를 입력자료로 강우예측을 수행한 결과 1시간 선행 예측의 경우 RMSE 3.98mm, CC 0.87, ME 0.69, 3시간 예측의 경우 RMSE 6.04 mm, CC 0.69, ME 0.34로 나타나 선행

예측 시간이 길어짐에 따라 예측력이 현저히 떨어지는 것을 확인 할 수 있었다. 여기에서 MAPLE 모형을 이용하여 강우를 예측하고자 할 경우 Mandapaka et al. (2012)의 연구결과에서 제시된 바와 같이 3시간 선행 예측자료의 적용성이 있을 것으로 판단된다.

3.4 예측 강우 기반의 토사재해 예경보

본 연구에서는 Kim et al. (2016)이 제시한 토사재해 예경보 강우기준을 이용하여 예측자료의 적용 가능성을 검토하였다. 대상지역에 7월 4일에 발생한 강우량에 대하여 6hr, 12hr, 24시간에 대한 누적강우를 산정하였으며 Nowcasting 개념의 AWS와 레이더를 이용하는 경우를 기준으로 Forecasting 개념의 선행예측을 수행하는 MAPLE 모형의 결과를 이용하는 경우(1hr, 2hr, 3hr)를 비교·평가하였다(Table 4 참고). 일례로 6시간 누적강우를 이용하여 토사재해 예경보를 수행한다고 한다면 매시를 기준으로 이전 6시간의 누적강우를 이용할 수 있다. 여기에서 예측 3시간 MAPLE 자료를 활용할 경우 예측 3시간을 포함하여 현재, 과거 2시간을 포함하는 총 6시간의 누적강우를 이용한 예경보를 수행하게 된다. 6시간 누적강우를 기준으로 강우위험기준을 넘기 시작하는 시간을 살펴볼 때, AWS 기준(Test-bed 지점)에서는 Watch 6:00 (>52.98mm), Warning 8:00(>82.91mm), Radar 기준에서는

Table 3. Statistical evaluation of validation and prediction results by ANN

	Validation	Prediction		
	Radar	MAPLE_1h	MAPLE_2h	MAPLE_3h
RMSE (mm)	3.15	3.93	5.33	6.04
CC	0.93	0.87	0.76	0.69
ME	0.81	0.69	0.48	0.34

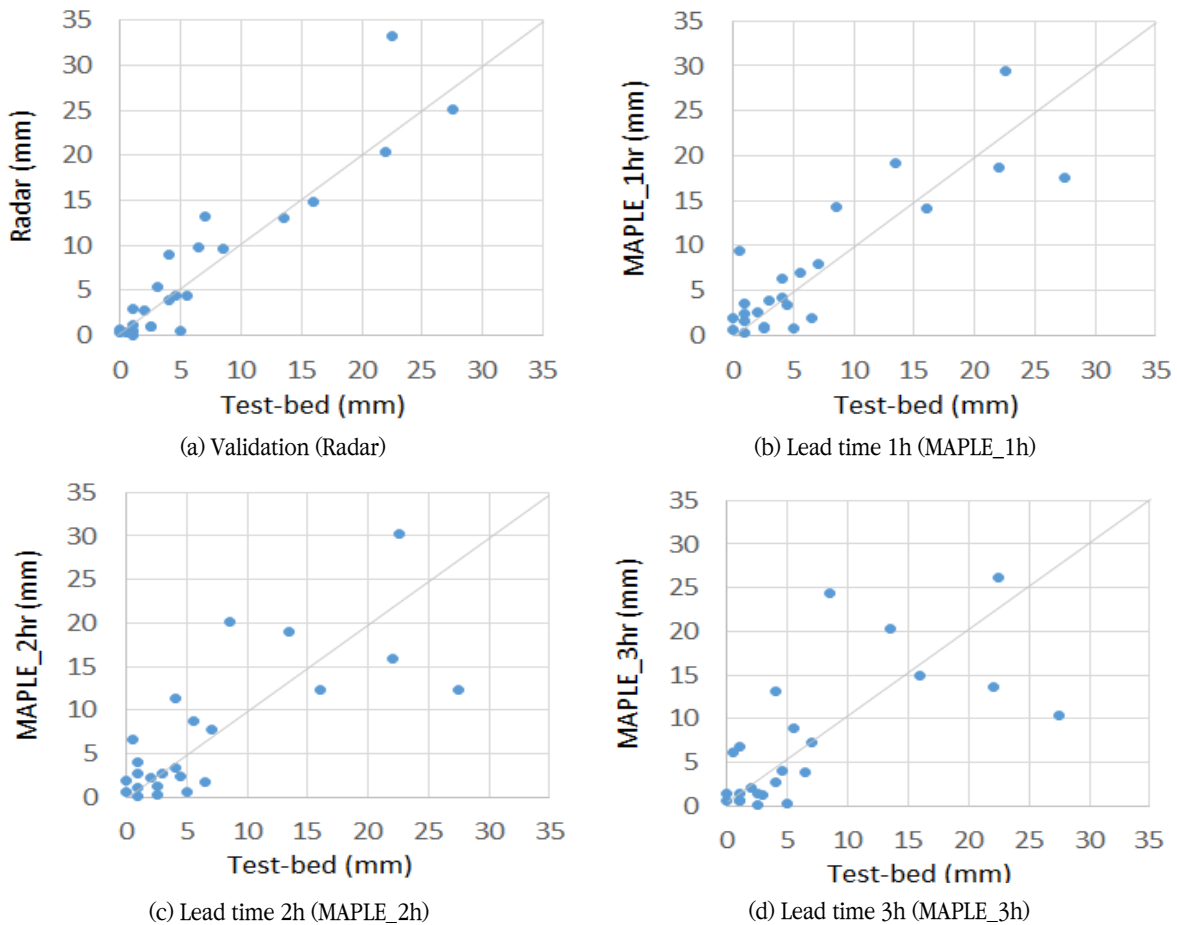


Fig. 6. Validation and prediction results by ANN

Table 4. Evaluation of rainfall prediction according to the rainfall criteria (mm)

lead time	<table border="1" style="display: inline-table; border-collapse: collapse;"> <tr> <td colspan="5">Watch</td> <td colspan="5">Warning</td> <td colspan="5">Alarm</td> </tr> </table>															Watch					Warning					Alarm				
	Watch					Warning					Alarm																			
	6hr					12hr					24hr																			
AWS	Radar	MAPLE			AWS	Radar	MAPLE			AWS	Radar	MAPLE																		
	0 hr	0 hr	1 hr	2 hr	3 hr	0 hr	0 hr	1 hr	2 hr	3 hr	0 hr	0 hr	1 hr	2 hr	3 hr															
0:00	4.5	4.4	5.3	9.3	18.2	4.5	4.4	5.3	9.3	18.2	4.5	4.4	5.3	9.3	18.2															
1:00	2.5	5.4	7.1	15.8	36.1	2.5	5.4	7.1	15.8	36.1	2.5	5.4	7.1	15.8	36.1															
2:00	1.0	5.9	12.8	31.9	58.0	1.0	5.9	12.8	31.9	58.0	1.0	5.9	12.8	31.9	58.0															
3:00	5.5	10.2	29.3	59.5	73.2	5.5	10.2	29.3	59.5	73.2	5.5	10.2	29.3	59.5	73.2															
4:00	13.5	23.3	52.7	68.5	83.4	13.5	23.3	52.7	68.5	83.4	13.5	23.3	52.7	68.5	83.4															
5:00	49.5	56.5	75.2	87.6	111.9	49.5	56.5	75.2	87.6	111.9	49.5	56.5	75.2	87.6	111.9															
6:00	67.0	72.5	86.6	106.8	117.2	71.5	76.9	91.1	111.2	121.6	71.5	76.9	91.1	111.2	121.6															
7:00	80.5	86.3	100.5	112.8	115.4	87.5	91.7	105.9	118.2	120.8	87.5	91.7	105.9	118.2	120.8															
8:00	88.0	95.3	112.9	116.2	118.3	96.0	101.2	118.8	122.1	124.2	96.0	101.2	118.8	122.1	124.2															
9:00	110.0	116.1	120.2	122.5	123.9	123.5	126.4	130.5	132.7	134.1	123.5	126.4	130.5	132.7	134.1															
10:00	100.5	107.0	109.5	112.3	113.6	127.5	130.3	132.8	135.5	136.9	127.5	130.3	132.8	135.5	136.9															
11:00	80.0	76.5	80.0	82.7	83.2	129.5	133.0	136.5	139.2	139.8	129.5	133.0	136.5	139.2	139.8															
12:00	59.0	57.3	61.1	61.3	62.8	126.0	129.8	133.6	133.7	135.2	130.5	134.2	138.0	138.2	139.6															
13:00	46.0	47.9	48.3	50.3	50.8	126.5	134.2	134.5	136.5	137.1	133.5	139.6	140.0	141.9	142.5															
14:00	38.5	38.4	40.3	41.5	42.0	126.5	133.7	135.7	136.8	137.3	134.5	139.6	141.6	142.7	143.2															
15:00	11.0	14.0	16.3	16.8	22.9	121.0	130.1	132.4	132.9	139.0	134.5	140.3	142.6	143.2	149.3															
16:00	8.0	12.9	13.5	20.2	33.4	108.5	120.0	120.6	127.2	140.4	135.5	143.2	143.8	150.5	163.7															
17:00	6.0	10.5	19.8	31.2	38.6	86.0	87.0	96.3	107.7	115.0	135.5	143.5	152.8	164.2	171.6															
18:00	5.5	9.7	16.1	23.8	27.6	64.5	67.0	73.4	81.1	84.9	136.0	143.9	150.2	157.9	161.8															
19:00	6.5	13.3	21.2	23.0	23.2	52.5	61.3	69.2	70.9	71.2	140.0	153.0	160.8	162.6	162.9															
20:00	12.5	26.5	28.4	29.0	29.2	51.0	64.9	66.8	67.4	67.6	147.0	166.1	168.0	168.6	168.8															
21:00	19.0	35.5	36.2	36.5	36.5	30.0	49.5	50.2	50.5	50.5	153.5	175.8	176.5	176.9	176.9															
22:00	23.0	33.2	33.9	33.9	33.9	31.0	46.1	46.8	46.8	46.8	158.5	176.4	177.1	177.1	177.1															
23:00	25.5	33.9	33.9	33.9	33.9	31.5	44.4	44.4	44.4	44.4	161.0	177.4	177.4	177.4	177.4															

Watch 6:00, Warning 7:00인 것으로 나타났다. 예측의 경우 1시간 예측의 경우 Watch 5:00, Warning 6:00인 것으로 나타났으며 선행예측 2시간과 3시간의 강우자료를 이용할 경우보다 이른 시간에 강우위험기준을 넘는 강우를 예측할 수 있는 것으로 나타났다. 24시간 누적강우를 이용할 경우에도 AWS 기준에서는 Watch 6:00 (>103.07mm), Warning 8:00 (>144.36mm)를 기준으로 검토할 때, MAPLE 예측강우를 이용할 경우에도 AWS를 이용할 경우보다 선행하여 토사재해 예경보를 발령할 수 있는 것으로 나타났다.

3.5 토의

본 연구에서는 토사재해 예경보를 위하여 초단기 예측강우의 적용성을 확인하고자 하였다. 이를 위하여 MAPLE 자료를 활용하였는데 레이더 강우의 합성장을 초기장으로 사용하는 MAPLE의 자료를 직접적으로 토사재해 예경보에 활용할 수는 없다. 이유는 레이더 강우의 경우 지상에 발생한 강우량을 직접 측정하는 방식이 아니기 때문에 간접적으로 대기에서 측정되는 강우를 지상 강우로 보정하는 과정이 필요하다. 따라서 MAPLE 자료 또한 레이더 자료와 마찬가지로 보정이 필요하며 본 연구에서는 이를 위하여

신경망 기법을 적용하였다. 여기에서 신경망을 이용할 경우 입력층으로 활용될 수 있는 자료는 관측(Nowcasting) 또는 예측(Forecasting)의 차이에 의하여 활용될 수 있는 자료에 차이가 난다. 일례로 Jun et al.(2016)의 연구에서는 Nowcasting을 위한 레이더 자료의 활용을 위하여 입력자료로 레이더 자료와 AWS 자료를 활용할 수 있었다. 하지만 Forecasting을 위해서 레이더 자료 대신에 MAPLE 자료를 사용할 수 있다하더라도 미래 AWS 자료가 부재하기 때문에 그만큼 활용할 수 있는 정보가 제한적이다. 이러한 이유는 예측자료의 정확성에도 영향을 미칠 수 있을 것으로 판단된다. 예측자료가 갖는 한계, 즉 MAPLE 예측자료의 부정확성도 대상지역에 강우량을 정확히 예측하는데 큰 영향을 주었다. 이에 따라 선행예측시간이 길어질수록 예측력이 현저히 저하됨을 확인하였다.

Kim et al.(2016)에 의하여 제시된 토사재해 예경보기준(강우위험기준)을 이용하여 초단기 예측강우를 토사재해 예경보에 활용할 수 있는지에 대한 검토를 수행하였다. Test-bed 지점의 AWS 결과와 비교한 결과 예측시간 또는 이보다 선행하여 토사재해 예경보가 가능함을 확인하였다. 하지만 예측강우 기반의 정확한 토사재해 예경보를 위해서

는 MAPLE에 의한 초단기 예측강우의 정확성이 우선적으로 담보되어야 한다. Table 4에서 확인한 바와 같이 본 연구에서 MAPLE을 이용하여 선행 예측한 강우량은 실제 Test-bed 지점에 발생한 강우량 보다 크게 추정되었다. 따라서 선행예측 시간 보다도 이른 시간(일례로 3시간 선행 예측강우를 활용하였지만 4시간 또는 5시간 전에 강우위험 기준을 넘음)에 예경보가 발령되어야 하는 상황이 발생하였다. 이러한 문제를 극복하기 위해서는 우선적으로 정확도가 우수한 초단기 예측강우를 생성되어야 한다. 더불어 이러한 노력과 함께 적극적으로 예측강우를 활용하는 연구가 토사재해 분야에 필요하다. 향후 예측강우의 불확실성에 대한 한계를 인식하고 예측가능시간을 검토함과 동시에 불확실성 기반의 토사재해 예경보 발령 방법론에 대한 연구가 필요할 것으로 판단된다.

4. 결 론

본 연구에서는 토사재해 발생에 가장 큰 영향을 미치는 강우량을 이용하여 토사재해 예경보를 수행할 경우 초단기 예측강우를 활용할 수 있는지에 대한 검토를 하였다. 초단기 예측자료를 활용하기 위한 방법으로 신경망 모형을 적용하였으며 레이더와 AWS의 관계를 이용하여 신경망을 학습하였다. 그리고 MAPLE에 의하여 생성된 예측강우를 입력자료로 1hr, 2hr, 3hr 선행예측을 수행하였다. 또한 6hr, 12hr, 24hr의 누적강우에 대한 토사재해 예경보기준을 이용하여 MAPLE 예측강우의 적용성을 Test-bed 지점에 설치한 AWS 강우량과 비교 평가하였다. 평가결과 MAPLE 예측강우를 이용할 경우 AWS를 이용할 경우 보다 선행(약 3시간 까지)하여 토사재해 예경보를 발령할 수 있음을 확인하였다. 하지만 예측강우의 정확성이 선행예측 시간이 길어짐에 따라 현저히 줄어드는 한계가 있었다. 따라서 토사재해 예경보 연구에서 이러한 문제를 극복하기 위한 지속적인 연구가 필요하다.

사 사

본 연구는 국토교통부/국토교통과학기술진흥원 건설기술 연구사업의 연구비지원(13건설연구S04)에 의해 수행되었습니다.

References

- Ahnert, PR, Krajewski, WF, and Johnson, ER(1986) Kalman filter estimation of radar-rainfall mean field bias, 23rd Radar Meteorology Conference, *American Meteorological Society*, pp. 33-37.
- Barbosa, S(1994). Brief Review of Radar-Raingauge Adjustment Techniques, *Advances in radar hydrology*, pp. 148-169.
- Choi, YS, Choi, CK, Kim, KT., and Kim, JH(2013). Evaluation of the Application of Radar Data for Local Landslide Warning, *J. of Wetlands Research*, 15(2), pp. 191-201.
- European Union (EU)(2011). *Work Package WP 4.1 - Short-term Weather Forecasting for Shallow Landslide Prediction*, Safe Land Project.
- Ham, DH and Hwang, SH(2014). Review of Landslide Forecast Standard Suitability by Analysing Landslide-inducing Rainfall, *J. of Korean Society of Hazard Mitigation*, 14(3), pp. 299-310.
- Jun, H, Lee, J, and Kim, S(2016). A Study on Use of Radar Rainfall for Rainfall-triggered Mud-debris Flows at an Ungauged Site, *J. of Korean Society on Water Environment*, 32(3), pp. 310-317.
- Kim, BS, Hong, JB, Kim, HS, and Choi, KH(2007). Combining Radar and Rain Gauge Rainfall Estimates for Flood Forecasting Using Conditional Merging Method, *J. of The Korean Society of Civil Engineers*, 27(3B), pp. 255-265.
- Kim, B, Jang, D, Yang, D, and Yoo, C(2009). A Review of Accuracy of the MAPLE as a Very Short-term Rainfall Forecast Model. *Water for Future*, *J. of Korea Water Resources Association*, 42(12), pp. 52-64.
- Kim, KH, Jung, HR, Park, JH, and Ma, HS(2011). Analysis on Rainfall and Geographical Characteristics of Landslides in Gyeongnam Province, *J. of the Korea Society of Environmental Restoration Technology*, 14(2), pp. 33-45.
- Kim, JH(1993). *A Study on Hydrological Forecast of Stream Flow Using Neural Network*, Doctor's Dissertation, Inha University.
- Kim, YT, Lee, JS, Kang, HS, and Ananta MSP(2016). 2016 *Fall Geosynthetics Conference*
- Lee, J, Oak, S, and Jun, H(2016). The Study of the Critical Depth and Critical Velocity of Casualties on Mud Flow, *J. of Korean Society of Hazard Mitigation*, 16(2), pp. 399-405.
- Lee, MJ, Lee, SR, and Jeon, SW(2012). Landslide Hazard Mapping and Verification Using Probability Rainfall and Artificial Neural Networks, *J. of the Korean Association of Geographic Information Studies*, 15(2), pp. 57-70.
- Liu, H, Chandrasekar, V, and Xu, G(2001). An Adaptive Neural Network Scheme for Radar Rainfall Estimation from WSR-88D Observations, *J. of Applied Meteorology*, 40(11), pp. 2038-2050.
- Mandapaka, PV, Germann, U, Panziera, L, and Hering, A(2012) Can lagrangian extrapolation of radar fields be used for precipitation nowcasting over complex alpine orography?, *Weather Forecast.*, 27, pp. 28-49.
- Ministry of Construction and Transportation in Korea(2007) A study on optimization of Imjin rainfall radar.
- Nash, JE and Sutcliffe, JV(1970). River Flow Forecasting through Conceptual Models. Part I-A: Discussion of Principles, *J. of Hydrology*, 10, pp. 283-290.

- National Institute of Meteorological Science in Korea(2009). Evaluation and application cases of weather radar, *10th workshop of weather radar*.
- National Oceanic and Atmospheric Administration and United States Geological Survey (NOAA and USGS). (2005) *NOAA-USGS Debris-Flow Warning System-Final Report*, National Oceanic and Atmospheric Administration and United States Geological Survey.
- Oh, J and Park, HJ(2014). Analysis of Landslide Triggering Rainfall Threshold for Prediction of Landslide Occurrence, *J. of Korean Society of Hazard Mitigation*, 14(2), pp. 115-129.
- Rosenblatt, F(1958). The Perceptron : A Probabilistic Model for Information Storage and Organization in the Brain, *Psychological Review*, 65, pp. 386-408.
- Safeland(2012). *Statistical and empirical models for prediction of precipitation-induced landslides*, Deliverable D1.5, p. 9.
- Sideris, IV, Germann, U, Gabella, M, and Panziera, L(2015) Nowcasting and large-radar-archive statistical learning in Switzerland, *10th Intern. Workshop on Precipitation in Urban Areas*, ETH Zürich, Institute of Environmental Engineering.
- Son, K, Kim, H, Lim KJ, and Jung, Y(2015) Study on Sediment Runoff Reduction using Vegetative Filter Strips in a Mountainous Watershed, *J. of Korean Society on Water Environment*, 31(4), pp. 407-417.
- Turner, BJ, Zawadzki, I, and Germann, U(2004) Predictability of Precipitation From Continental Radar Images. Part III: Operational Nowcasting Implementation (MAPLE), *J. Appl. Meteorol.*, 43, pp. 231 - 248.
- Wilson, JW, and Brandes, EA(1979) Radar measurement of rainfall, *Bull. Amer. Meteor. Soc.*, 60, pp. 1048 - 1058.
- Zawadzki, I, Bellon, A, and Kilambi, A(2007) *Nowcasting of Prediction by Variational Echo Tracking*, Department of Atmospheric and Oceanic Sciences McGill University, Montreal, Canada