

항공사진을 이용한 산사태 탐지 및 인공신경망을 이용한 산사태 취약성 분석

오 현 주[†]

한국지질자원연구원 지질정보센터

Landslide Detection and Landslide Susceptibility Mapping using Aerial Photos and Artificial Neural Networks

Hyun-Joo Oh[†]

Geoscience Information Department, Korea Institute of Geoscience and Mineral Resources (KIGAM)

Abstract : The aim of this study is to detect landslide using digital aerial photography and apply the landslide to landslide susceptibility mapping by artificial neural network (ANN) and geographic information system (GIS) at Jinbu area where many landslides have occurred in 2006 by typhoon Ewiniar, Bilis and Kaemi. Landslide locations were identified by visual interpretation of aerial photography taken before and after landslide occurrence, and checked in field. For landslide susceptibility mapping, maps of the topography, geology, soil, forest, lineament, and landuse were constructed from the spatial data sets. Using the factors and landslide location and artificial neural network, the relative weight for each factors was determinated by back-propagation algorithm. As the result, the aspect and slope factor showed higher weight in 1.2-1.5 times than other factors. Then, landslide susceptibility map was drawn using the weights and finally, the map was validated by comparing with landslide locations that were not used directly in the analysis. As the validation result, the prediction accuracy showed 81.44%.

Key Words : Landslide susceptibility, Geographic information system (GIS), Artificial neural network (ANN), Weight, Aerial photography, Jinbu.

요약 : 본 연구의 목적은 2006년 태풍 에위니아, 빌리스, 개미와 집중호우로 인해 많은 산사태가 발생한 진부면 지역을 대상으로 항공사진을 이용한 산사태 탐지 및 인공신경망과 GIS를 이용한 산사태 취약성을 분석하는데 있다. 산사태 위치는 산사태 발생 전후의 항공사진을 판독 후 현장에서 확인하였다. 취약성 분석을 위해 지형, 지질, 토양, 임상, 선구조, 토지이용도 등의 자료는 공간 데이터베이스로 구축하였다. 산사태와 관련 요인들간의 상대적 가중치는 인공신경망의 역전파 알고리즘을 이용하여 결정하였다. 그 결과 경사 방향과 경사는 다른 요인들 보다 1.2~1.5배 높게 나타났다. 이 가중치를 이용하여 취약성도를 작성 후 분석에 사용하지 않은 산사태 위치와 비교하여 검증하였다. 그 결과 예측 정확도는 81.44%로 나타났다.

접수일(2010년 2월 5일), 게재확정일(2010년 2월 15일).

[†]교신저자: 오현주(ohj@kigam.re.kr)

1. 서 론

지구온난화 및 이상고온의 증가 추세로 세계 곳곳에서는 태풍 및 집중호우가 빈발화되고 있어 산사태 발생에 대한 우려가 커지고 있다. 산사태는 인명, 재산, 산림, 시설물 등에 피해를 주기 때문에 사전에 산사태 취약지역을 예측함으로서 피해를 예방해야한다. 산사태 취약지역을 예측하기 위해 우선 산사태 발생지의 정확한 위치와 특성을 알아야한다. 연구지역이 광역 또는 산악지역일 경우 현장조사를 통한 산사태 위치 파악은 많은 시간, 인력 및 비용이 소비될 것이다. 하지만 항공사진의 이용은 이러한 현장조사의 어려움을 줄일 수 있으며 산사태의 규모와 위치를 정확하게 판독 할 수 있다.

산사태는 지질, 지형, 임상, 토양 등의 지공간 환경인 자들이 복합적으로 작용하여 발생되기 때문에 지리정보시스템(GIS)을 이용한 공간분석이 필요하다. 하지만 GIS는 대용량의 다차원 자료에 내재되어있는 사건발생과 관련된 정보를 탐지하거나 사건발생을 예측할 수 있는 기능이 미흡하다. 지공간과 관련된 응용연구에서는 공간 데이터베이스 내에 잠재되어 있는 복잡한 정보, 공간적 상관관계 및 패턴을 효율적으로 찾아내고, 미래 사건발생의 예측을 위해 GIS와 확률, 통계, 패턴인식 기법들이 사용되고 있다. 이러한 기법들은 1990년대부터 산사태 분석에 사용되었고(Carrara, et al., 1991, Van Westen and Terlien, 1996, Lee, et al., 2002, 2003, 2004a), Lee, et al.(2007, 2006, 2004, 2003, 2002) 와 Lee(2005, 2007a, 2007b)은 GIS와 Weight of evidence, 빈도비, 인공신경망 기법을 이용하여 국내외 여러 지역에 대한 산사태 취약성을 분석한 바 있다.

일반적으로 기법의 성능은 분석에 사용하지 않은 사건자료에 대한 검증으로 평가된다(Alman and Ningfang, 2001). 분석 기법은 많은 사건자료로 훈련된다면 새롭게 추가되는 사건자료에 대해 정확한 예측 결과를 도출 할 수 있다. 산사태 위치 선정에서는 산사태 발생지의 접근이 곤란할 경우 위성사진과 항공사진을 이용하여 많은 산사태 위치를 판독할 수 있다. 하지만 위성영상은 산사태 규모가 큰 경우에만 산사태 위치 판독이 가능하고, 아날로그 항공사진(8bit)은 디지털 항공사진(12bit)에 비해 낮은 방사해상력을 갖고 있어 음영지에 대한 판독력이 낮으며 필름의 현상과 스캔과정으로 인한 이미

지 왜곡이 나타날 수 있다. 따라서 본 연구에서는 디지털 항공사진 이용한 산사태 발생지의 정확한 판독과, 인공신경망을 이용한 산사태 취약성도 작성 및 교차검증을 수행하였다.

2. 연구지역

세계적인 기후변동으로 우리나라에는 태풍과 국지성 호우가 증가하고 있다. 1998년 태풍 예니, 2002년 루사, 2003년 매미의 영향으로 산사태 및 산림피해가 급격히 늘었으며 특히 2006년도에는 태풍 에워니아, 벌리스, 개미로 인하여 수많은 산사태가 발생하였다. 2006년도에는 평년보다 두 배 이상의 강우(758mm)를 기록하였고, 7월 한 달간 전국적으로 1조 5천억원의 재산피해가 발생한 것으로 파악되었다(워터저널, 2007). 강원도에는 약 2일에 걸쳐 675mm의 집중호우가 내려 전국 피해액의 95.4%를 차지하였고 인제군 및 평창군을 중심으로 수많은 산사태가 발생하였다. 또한 평창군은 3시간 연속 최대 강우량이 209mm로 500년에 한 번 있을 정도의 강우량을 기록하였다. 연구지역은 평창군에서 산사태가 가장 많이 발생한 진부면으로 선정하였고 지리좌표상 위도 $37^{\circ} 35' 2'' \sim 37^{\circ} 40' 26''$ N, 경도 $128^{\circ} 29' 49'' \sim 128^{\circ} 35' 36''$ E 사이에 위치한다(Fig. 1).

3. 인공신경망

인공신경망(Artificial Neural Network)은 인간 두뇌의 신경세포들 간의 연결 관계를 모델링한 것으로서 즉, 시냅스의 결합으로 네트워크를 형성한 뉴런(노드)이 반복 학습을 통해 시냅스의 결합 세기를 변화시켜 자료 내에 숨어있는 패턴을 찾아내는 모델링 기법이다. 신경망의 기본요소는 처리 노드이며, 여러 개의 노드가 각 층별로 배열(입력층 : x_1, x_2, \dots, x_a , 은닉층 : y_1, y_2, \dots, y_b , 출력층 : z_1, z_2, \dots, z_c)되며, 노드들의 출력은 층간 가중치(W_{ji}, W_{kj})를 통해서 확대 또는 감소되어 다른 층의 노드로 전달된다(Fig. 2). 입력층과 출력층 사이에 하나 이상의 중간층이 존재하는 신경망을 다층 퍼셉트론(Multilayer perceptron)이라고 한다. 다층 퍼셉트론

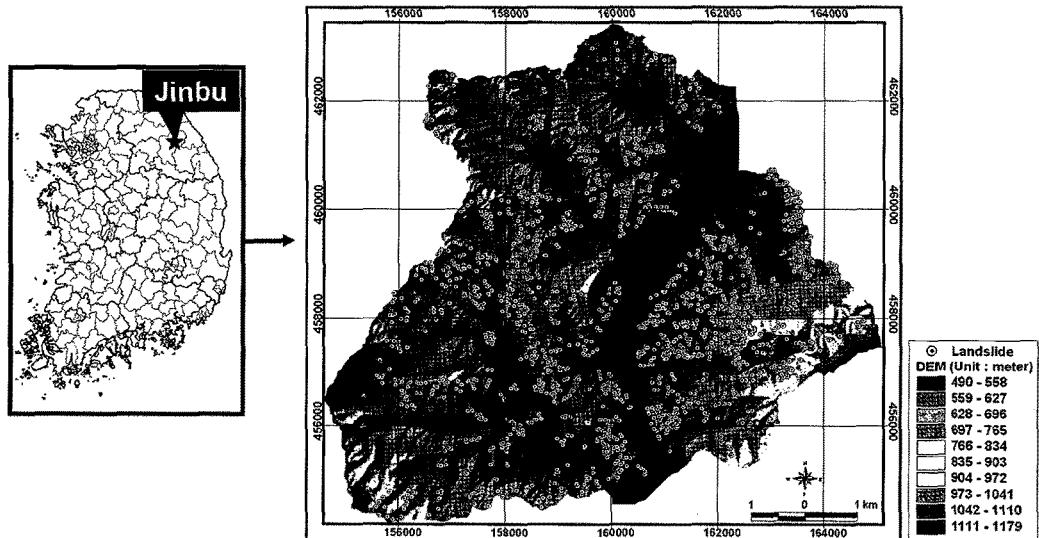


Fig. 1. DEM of study area with landslide location.

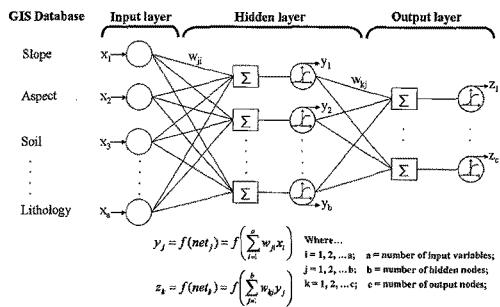


Fig. 2. The architecture of the artificial neural network.

에서 사용되는 알고리즘은 오류 역전파 알고리즘으로써 목표 출력값과 실제 출력값과의 차(에러)이의 제곱을 가장 최소화하여 최적의 결과를 도출하고, 이에 관련된 입력 자료들의 가중치를 계산한다(Paola and Schowengerdt, 1995).

하나의 입력 훈련 패턴에 대한 에러는 E 로, 기대되는 출력 벡터의 함수는 d 로, 실제 출력 벡터는 o 로 표시한다(식 (1)).

$$E = \frac{1}{2} \sum_k (d_k - o_k)^2 \quad (1)$$

이러한 에러는 인공 신경망을 통하여 역으로 전파되는데, 일반적으로 층간 가중치를 변화시킴으로써 최소화하게 된다(식 (2)).

$$\Delta w_{ji}(n+1) = \eta(\delta_j \cdot o_i) + \alpha \Delta w_{ji}(n) \quad (2)$$

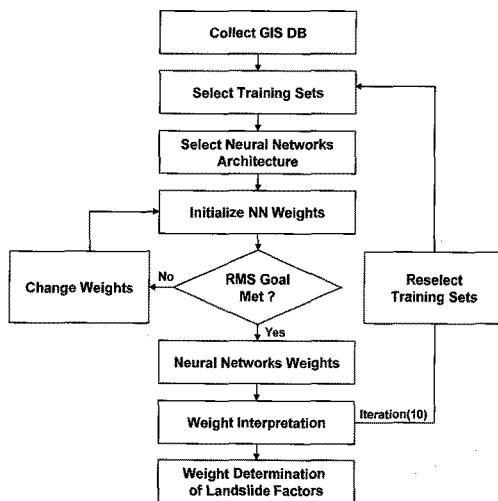


Fig. 3. Flow chart for determination of weight.

여기서 η 는 학습률 변수이며, δ_j 는 에러의 변화비를 나타내며, α 는 모우멘텀 변수이다. 앞으로 나아가며 계산되는 신호 값과 역전되는 에러의 과정이 반복되어 에러를 최소화하고 기대 값에 도달하게 된다. Fig. 3은 가중치 결정을 위한 인공신경망 트레이닝의 흐름도이다. 본 연구에서는 Hines(1997)에 의해 MATLAB으로 개발된 역전파 인공신경망 프로그램을 기초로 하여 산사태 취약성 분석에 적합하도록 수정 및 보완하여 사용하였다.

3. 산사태 탐지

산사태 취약성 분석에 있어서 기존의 산사태 위치는 앞으로 산사태가 일어날 수 있는 환경적 조건 이해하는데 중요한 역할을 한다. 그러므로 정확한 산사태 위치를 선정해야 최적의 분석 결과가 도출될 수 있다. Daum (www.daum.net)에서 제공하는 50cm 급 항공사진은

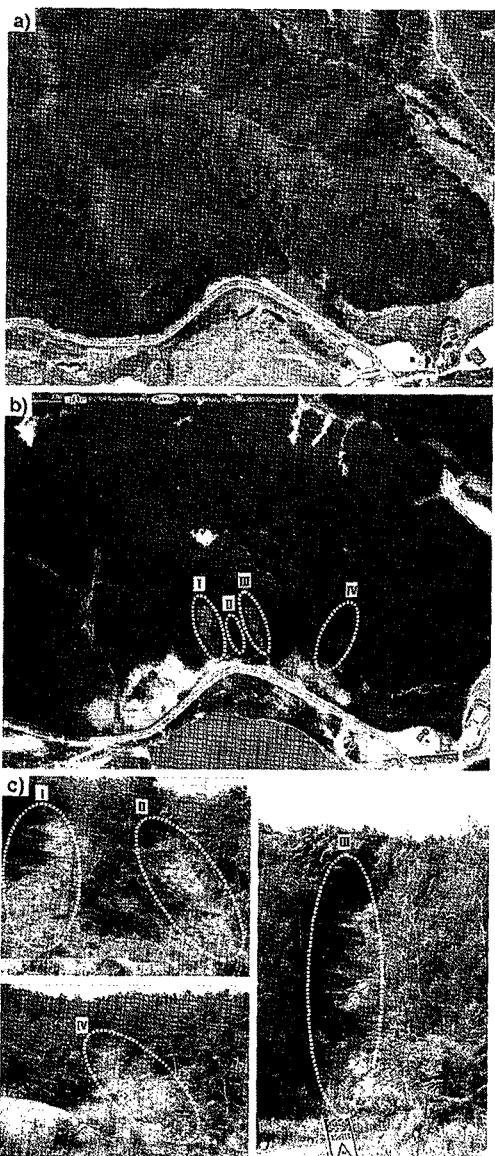


Fig. 4. Selection of landslide occurrence; a) analog aerial photograph by NGII, b) digital aerial photograph by DAUM and c) field survey photo.

2007년부터 삼아항업주식회사(Samah Aerial Survey Co., Ltd; www.samah.com)에서 UltraCam-X 디지털 카메라를 이용하여 촬영한 것이다. 이 카메라의 영상은 12bit 이상의 방사해상능력을 갖고 있어 기존의 아날로그 영상(8bit)에 비해 지형변화에 대한 판독이 뛰어나고, 이미지 왜곡이 제거된 높은 해상도의 영상을 제공한다(Schneider and Gruber, 2008). 그러므로 디지털 항공사진은 위성영상이나 아날로그 항공사진보다 산사태 구조에 상관없이 정확한 산사태 위치를 선정하는데 유용하다.

따라서 본 연구에서는 2006년에 발생한 산사태 전후의 항공사진을 비교·탐지하여 정확한 산사태 발생지 선정하였다. 산사태 발생 전의 항공사진은 국토지리정보원(National Geographic Information Institute, NGII)에서 발행하는 1/20,000 축척의 항공사진(촬영일: 2005.04.04)을, 산사태 발생 후의 항공사진은 Daum에서 제공하는 50cm급 항공사진(촬영일: 2008.03.04)을 수집하였다. 정사보정된 두 항공사진을 비교하여 판독한 산사태 위치는 현장조사에서 실제 산사태 위치와 정확하게 일치하였다(Fig. 4). 이러한 작업 절차를 통하여 판독된 산사태는 1,803개로 산사태 좌표를 추출 후 ArcGIS 9.0 환경에서 점 형태의 공간자료로 구축하였다(Fig. 3).

4. 공간 데이터베이스

산사태는 지질, 지형, 임상, 토양 등의 상호작용에 의해 발생되기 때문에 산사태 분석시 관련 요인들은 공간 데이터베이스로 구축되어야 한다. 취약성 분석을 위해 수집된 자료는 Table 1과 같이 산사태 분포도, 지형도, 지질도, 토지이용도, 임상도, 토양도 등이다. 지형도에서는 경사, 경사방향, 곡률, Topographic Wetness Index(TWI), Stream Power Index(SPI), 선구조를, 토양도에서는 지형, 배수, 모재, 유효토심 및 토질을, 임상도에서는 경급, 임상, 밀도 및 영급을, 지질도에서는 암상을 추출하였다. 산사태와 관련있는 모든 요인들은 입력자료의 축척과 연구지역의 크기를 고려하여(Lee, et al., 2004) 10m × 10m 격자 크기를 갖는 공간 데이터베이스로 구축하였다(Fig. 5). 연구지역의 공간자료는

Table 1. Data layer related to landslide of study area

| Category | Factors | Data Type | Scale |
|-----------------------|--|-----------|----------|
| Geological hazard map | Landslide | Point | 1:5,000 |
| Topographic map | Slope Aspect Curvature TWI SPI Lineament | GRID | 1:5,000 |
| Forest map | Timber diameter Timber type Timber density Timber age | Polygon | 1:25,000 |
| Soil map | Topography Soil drainage Soil material Soil thickness Soil texture | Polygon | 1:25,000 |
| Geological map | Geology | Polygon | 1:50,000 |
| Land use map | Land use | Polygon | 1:5,000 |

ArcGIS 9.0을 이용하여 구축하였고, 격자수는 행과 열이 923 × 1,053으로 총 597,884개로 설정하였다.

1) 산사태

사공간 개념이 내포된 예측도의 검증은 같은 지역에서 다른 시기에 발생한 사건자료가 요구된다. 하지만 지질학적 사건들은 같은 지역에서 다른 시기에 발생할 사건의 수가 적을 수 있고 사건이 발생했더라도 기록 없이 복구 작업으로 사건의 흔적이 없어진다면 다른 시기의 사건자료를 수집하기란 한계가 있다. 연구지역의 산사태 역시 2006년도에만 집중적으로 발생하였기 때문에 다른 시기의 산사태 자료를 수집하기란 어려움이 있었다. 이러한 검증자료 수집의 한계로 본 연구에서는 수집된 사건자료를 훈련용(70%)과 검증용(30%)으로 무작위 분류하여 취약성 분석과 이의 검증에 사용하였다. 훈련 및 검증 자료의 분류는 검증 자료가 모집단을 대표하는 가에 대한 문제가 제기될 수 있다. 이는 사건의 개수와도 결부된다. 만약 사건의 개수가 적다면 모집단을 설명할 능력이 떨어지고 이의 취약성도 역시 낮은 정확도를 보일 것이다. 하지면 연구지역의 산사태 발생지는 디털 항공사진을 이용하여 접근이 어려운 지역까지 정확히 판독되었고, 총 1,803곳으로 파악되었다.

2) 지형요인

지형의 형태는 토양의 물리화학적 특성과 지표수, 지하수의 집중 및 이동 등에 큰 영향을 준다. 그러므로 지형의 요인들은 집중호우시 산사태 발생에 영향을 줄 수 있다(Johnes, 1983). 산사태와 관련있는 지형 요인들은 국립지리원 발행의 1:5,000 수치지형도를 이용하여 작성한 수치표고모델(DEM)로부터 경사, 경사면의 방향, 곡률, TWI (Topographic Wetness Index), SPI (Stream Power Index) 등을 추출하였고 음영기복도에서는 선구조를 추출하였다. 사면의 경사(Fig. 5a)는 물질의 추진력에 크게 영향을 끼치므로 산사태를 유발하는 요인들의 상황이 같으면 산사태는 급한 사면에서 잘 일어나지만, 평균적으로 45 도 이상의 사면경사에서는 토층이 발달하지 않으므로 토사 산사태 발생 가능성이 오히려 낮다. 경사면은 방향(Fig. 5b)에 따라 지표의 함수량, 식생의 종류 및 토양의 강도가 다를 수 있으므로 산사태에 취약한 정도도 다를 수 있다. 사면의 곡률(Fig. 5c)은 오목형, 평형, 볼록형 사면으로 구분할 수 있다. 오목한 사면은 볼록한 사면보다 산사태에 더 취약할 수 있다. 우기동안 오목한 사면은 볼록한 사면보다 더 많은 수분을 함유할 수 있고 토양의 강도가 감소하면서 침식이 진행될 수 있다(Leesing, et al., 1976). 하지만 경사 분포나 토양의 물성변화, 산사태 발생 시작점의 선정, 분석의 격자크기등과 같은 복합적 특성의해 산사

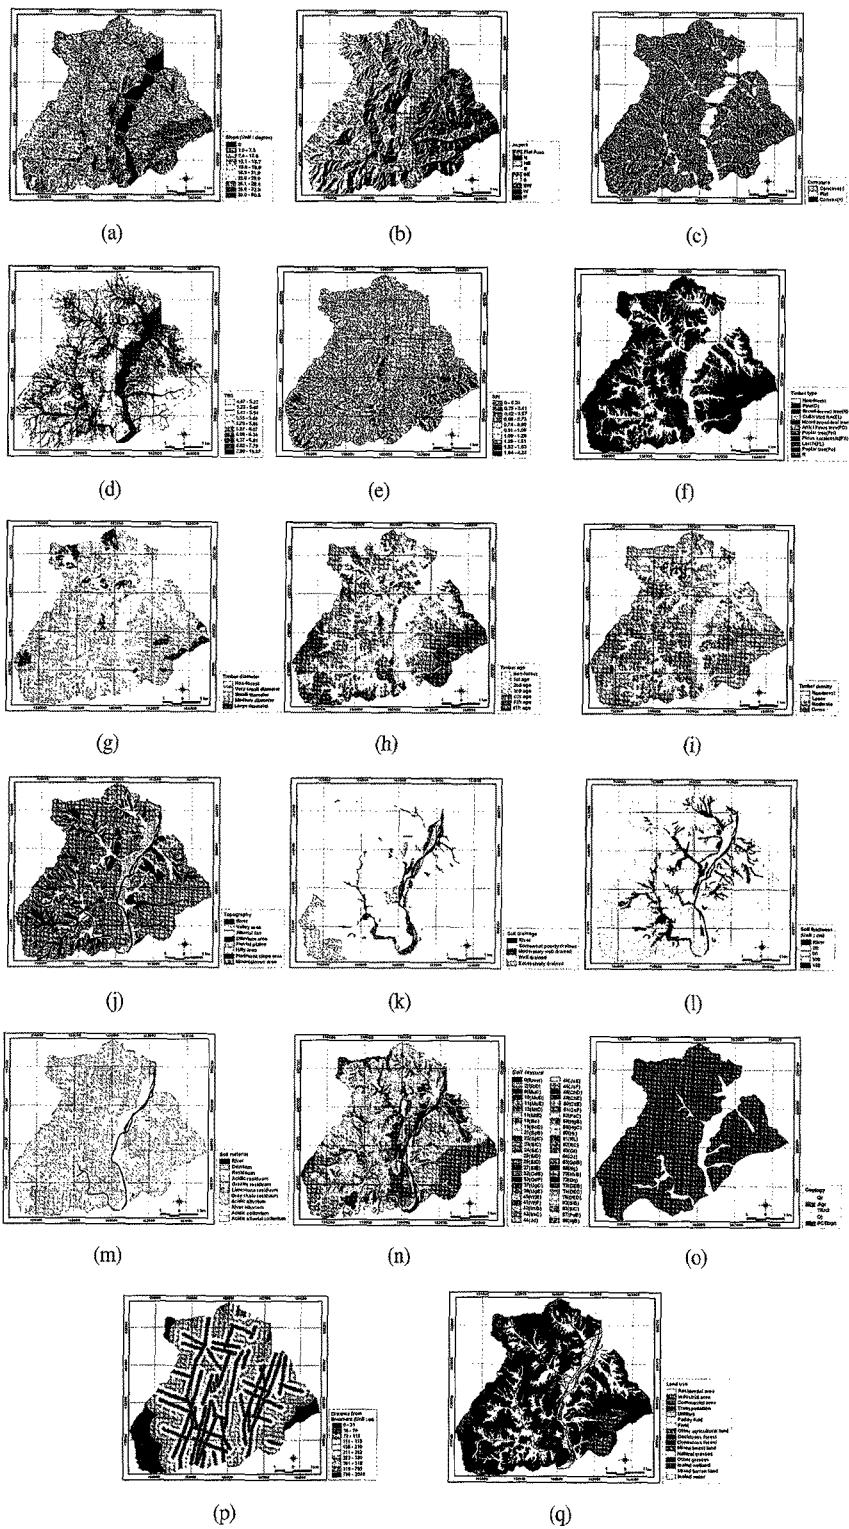


Fig. 5. Constructed spatial database for landslide susceptibility analysis.

태에 취약한 곡률의 모양은 달라질 수 있다(Ohlmacher, 2007). 물의 유동은 사면의 다른 요인들보다 중요하다. 물의 유동과 관련된 수리적 지형 요인에는 TWI와 SPI가 있다(Beven and Kirkby, 1979, Moore, et al., 1993). TWI(Fig. 5c)는 토양의 물리·화학적 속성들의 균일하다는 가정하에 식 (3)로 표현된다(Wilson and Gallant, 2000). $\tan\beta$ 는 지표면의 한 점에서의 경사이고, α 는 단위격자 길이의 경사면의 면적이다. TWI는 지표면의 물의 유동 및 함유지의 공간적 패턴을 유추할 수 있는 요인으로써 경사 면적이 넓은 곳에서는 TWI 값이 크고 경사가 급한 곳에서는 TWI 값이 작을 것이다. SPI(Fig. 5d)는 지표면의 단위 면적당 물의 유출량이 일정하다는 가정하에 물의 유출에 따른 퇴적물의 이동 및 침식률을 유추할 수 있는 요인이다(식 4).

$$TWI = \ln\left(\frac{\alpha}{\tan\beta}\right) \quad (3)$$

$$SPI = \alpha \tan\beta \quad (4)$$

α : Upslope contributing area per unit contour length
 $\tan\beta$: Local slope

3) 임상도

식생은 사면위에 떨어지는 비의 충격을 완충하여 사면위의 침식을 막으며, 식생의 뿌리는 토양의 전단강도를 증가시켜 사면의 안정성을 높여준다. 그러므로 식생의 유무는 산사태 발생에 중요한 요인이다. 산사태와 관련있는 임상 요인들은 국립산림과학원 발생의 4차 1:25,000 수치임상도로부터 임상, 경급, 영급 및 밀도를 추출하였다. 임상은 수종(Fig. 5f)에 따라 산림을 구획한 것을 말하고, 우세하게 점유하고 있는 침엽수나 활엽수의 비율에 따라 침엽수흔효림, 활엽수흔효림, 침활흔효림 등으로 나눈다(김철민, 2008). 경급(Fig. 5g)은 치수, 대경목, 중경목, 소경목으로 구분하며, 항공사진상에서 측정한 수목의 수관직경과 현지조사시 측정한 수목의 흥고직경과의 관계를 따져서 치수, 소, 중, 대경목의 네 단계로 구분한다. 영급(Fig. 5g)은 구획한 산림의 평균적인 나이를 나타내는 것으로 10년 단위로 구분하고, 1~6영급으로 구분한다. 소밀도(Fig. 5i)는 수관의 올폐 정도를 나타내며 항공사진에서 수관밀도측정 규정을 이용하여 측정하고 소, 중, 밀의 세 단계로 구분한다.

4) 토양도

일반적으로 토층은 암반층보다 산사태의 발생 빈도가 훨씬 높다. 토양은 종류 및 성분에 따라서 강우에 의해 포화되는 속도가 다르므로 포화된 토양은 전단응력의 감소로 인하여 산사태가 일어날 수 있다. 따라서 산사태와 관련있는 토양 요인들은 농촌진흥청 발행의 1:25,000 정밀토양도로부터 지형, 배수, 모재, 유효토심 및 토질을 추출하였다. 땅의 생기 모양이나 형세를 나타내는 지형(Fig. 5j)은 산악지, 산록경사지(산기슭의 경사진 곳에 봉적된 토양), 선상지, 하성평탄지(하천의 충적 층을 모재로 하여 형성된 넓은 평탄지역), 곡간지(산과 산사이 골짜기에 퇴적된 토양), 구릉지(해발고도 200~600m의 완만한 기복을 이루고 있는 지형) 및 홍적대지(강 또는 하천에 접해있는 평탄 내지 약한 경사지)로 구분된다. 배수(Fig. 5k)는 토양의 배수정도를 나타내며, 유거, 투수정도, 지하수위, 산화철의 반문량 등에 의해 결정되고, 배수의 등급은 약간불량(특성 : 회갈색, 회색계, 황적색 반문 20%이상, 지하수위 50~100cm), 약간양호(특성 : 갈황색, 적색, 반문 약간 있음, 지하수위 100cm 내외), 양호(특성 : 황갈색, 갈색, 적갈색, 반문 없음, 지하수위 100~150cm) 및 매우양호(특성 : 황갈색 및 적색계, 반문 전혀 없음, 지하수위 150cm 이하)로 구분된다. 유효토심(Fig. 5l)은 작물 뿌리가 땅속으로 충분히 뻗을 수 있는 깊이로 토양 단면중 집적층까지를 말한다. 유효토심 등급은 매우 얕음(0~20cm), 얕음(20~50cm), 보통(50~100cm) 및 깊음(100~150cm)으로 구분된다. 토질(Fig. 5m)은 모래, 미사 및 점토의 상대적인 비율로 구분되고, 지역명, 토질 및 경사정보가 들어간 코드로 구분되었다. 경사의 기호는 A(0~2%, 평탄지), B(2~7%, 매우 약한 경사지), C(7~15%, 약한 경사지), D(15~30%, 경사지), E(30~60%, 심한 경사지), F(>60%, 매우 심한 경사지)로 구분된다. 모재(Fig. 5n)의 속성은 회색혈암·잔적층, 화강암·잔적층, 산성암·잔적층, 산성암·봉적층, 산성암·충적층, 산성암·충적층, 하성·충적층, 석회암·잔적층, 잔적층 및 홍적층으로 구분되어 있다.

5) 지질 및 선구조 분포도

연구지역의 지질도는 대한지질학회에서 발행한 1:50,000 하진부 도록이고, 지질은 남서부에 분포된 선

캠브리아기의 흑운모 편마암을 기반으로 그 위에 부정 합으로 놓여있는 조선계 석회암층과 평안계 녹암층은 광범위한 임계화강암의 관입을 받고, 임계화강암은 연구지역에 가장 넓게 분포하고 있다(Fig. 5o). 진부면을 통과하는 NNE-SSW 방향의 주단층은 좌수향 주향이 동 단층이며, 약 4km 간격으로 4개조로 이루어져 있다. 그중 2개조가 연구지역을 통과하고 있으며, 주 단층 사이에는 전단단층이 수개조로 통과하고 있다(Fig. 5p). 2 차 수반단층은 NNW-SSE 방향의 주향을 유지하면서 좌수향 주향이동 단층 운동의 감각을 보이고 있다. 최후 기에는 WNW-ESE 방향의 주향이동 단층이 통과하고 있다.

6) 토지이용도

토지이용 자료는 국토지리정보원 발행의 1:25,000 토지이용도로부터 추출하였다. 토지이용도의 속성값은 SPOT 영상으로부터 중분류 되었고, 주거, 공업, 상업, 교통, 공공시설, 논, 밭, 기타재배지, 낙엽활엽수림, 침엽수림, 혼효림, 자연초지, 기타초지 및 내륙습지로 구분되어 있다(Fig. 5q).

5. 분석 결과

역전파 알고리즘의 훈련과정은 산사태 발생지역과 산사태가 발생하지 않을 지역을 신경망에 정확히 인지시키는 작업으로써 훈련과정을 통하여 산사태와 관련된 각 요인별 가중치를 계산하게 된다. Paola와 Schowengerdt (1995)는 인공신경망 분석시 산사태 발생지역과 미 발생 지역에 대한 대표값을 선정하는게 가장 중요하다고 하였다. 따라서 연구지역의 산사태 발생지와 미 발생지역은 훈련용 산사태 위치와 경사도가 0인 지역을 대상으로 격자 1,261개를 무작위로 추출하였다. 그리고 산사태와 관련 요인들의 값은 0.1에서 0.9 사이의 값을 갖도록 정규화 하였다. 이는 인공신경망에서 추론능력의 향상을 위해 사용하는 시그모이드 함수가 0에서 1사이의 값을 갖기 때문이다. 여기서 역전파 알고리즘에 의해 기대되는 산사태 발생지의 최대값은 0.9가 된다. 그래서 기대되는 출력값과 실제 출력값 사이의 오차를 0.1까지 줄여 나가기 위해 반복적으로 역전파 알고리즘을 실행하였고 이를 통하여 각 요인별 가중치를 결정하였다 (Table 2). 가중치를 계산하기 위해 인공신경망 구조는 $17 \times 34 \times 1$ 로 설정하였고, 목표 오차에 도달하기 전의

Table 2. Weight of each factors calculated by neural network

| Factors \ Run | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | Mean | S.D. | N.W.* |
|-----------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| Slope | 0.0726 | 0.0668 | 0.0668 | 0.0761 | 0.0845 | 0.0767 | 0.0744 | 0.0704 | 0.0799 | 0.0776 | 0.0746 | 0.0053 | 1.4290 |
| Aspect | 0.0842 | 0.0788 | 0.0788 | 0.0751 | 0.0867 | 0.0835 | 0.0753 | 0.0737 | 0.0837 | 0.0646 | 0.0784 | 0.0062 | 1.5030 |
| Curvature | 0.0548 | 0.0456 | 0.0456 | 0.0689 | 0.0579 | 0.063 | 0.0594 | 0.054 | 0.053 | 0.0609 | 0.0563 | 0.0070 | 1.0789 |
| TWI | 0.0520 | 0.0585 | 0.0585 | 0.0505 | 0.0437 | 0.0561 | 0.0516 | 0.0566 | 0.0627 | 0.0442 | 0.0534 | 0.0059 | 1.0240 |
| SPI | 0.0640 | 0.0672 | 0.0672 | 0.0502 | 0.0716 | 0.0589 | 0.0544 | 0.0461 | 0.0469 | 0.0612 | 0.0588 | 0.0086 | 1.1261 |
| Lineament | 0.0446 | 0.0525 | 0.0525 | 0.0592 | 0.0593 | 0.064 | 0.042 | 0.0626 | 0.0617 | 0.0591 | 0.0558 | 0.0072 | 1.0682 |
| Geology | 0.0598 | 0.0551 | 0.0551 | 0.0472 | 0.0459 | 0.0578 | 0.0568 | 0.0545 | 0.055 | 0.0549 | 0.0542 | 0.0041 | 1.0387 |
| Land use | 0.0504 | 0.0553 | 0.0553 | 0.0584 | 0.0464 | 0.0583 | 0.0565 | 0.0534 | 0.054 | 0.0591 | 0.0547 | 0.0037 | 1.0483 |
| Timber diameter | 0.0701 | 0.0581 | 0.0581 | 0.0519 | 0.0551 | 0.0563 | 0.0676 | 0.0539 | 0.0623 | 0.0547 | 0.0588 | 0.0057 | 1.1268 |
| Timber type | 0.0570 | 0.0613 | 0.0613 | 0.0783 | 0.0507 | 0.0651 | 0.0474 | 0.0572 | 0.0485 | 0.0636 | 0.0590 | 0.0087 | 1.1313 |
| Timber density | 0.0516 | 0.0695 | 0.0695 | 0.0497 | 0.0612 | 0.0497 | 0.0558 | 0.0463 | 0.0607 | 0.0596 | 0.0574 | 0.0078 | 1.0991 |
| Timber age | 0.0642 | 0.0533 | 0.0533 | 0.0583 | 0.0547 | 0.0489 | 0.0623 | 0.0574 | 0.0681 | 0.0583 | 0.0579 | 0.0055 | 1.1090 |
| Topography | 0.0622 | 0.0494 | 0.0494 | 0.0593 | 0.052 | 0.0502 | 0.0641 | 0.0678 | 0.0581 | 0.0575 | 0.0570 | 0.0062 | 1.0922 |
| Soil drainage | 0.0570 | 0.0647 | 0.0647 | 0.0626 | 0.0649 | 0.0493 | 0.0647 | 0.0603 | 0.0518 | 0.0526 | 0.0593 | 0.0058 | 1.1355 |
| Soil material | 0.0497 | 0.0469 | 0.0469 | 0.0613 | 0.0564 | 0.0508 | 0.0552 | 0.0759 | 0.0515 | 0.0677 | 0.0562 | 0.0090 | 1.0774 |
| Soil thickness | 0.0478 | 0.0563 | 0.0563 | 0.0445 | 0.0653 | 0.0538 | 0.0592 | 0.0583 | 0.0627 | 0.0557 | 0.0560 | 0.0059 | 1.0728 |
| Soil texture | 0.0579 | 0.0605 | 0.0605 | 0.0486 | 0.0438 | 0.0576 | 0.0533 | 0.0517 | 0.0393 | 0.0487 | 0.0522 | 0.0068 | 1.0000 |

* Normalized weight with respect to soil texture

S.D. : Standard deviation

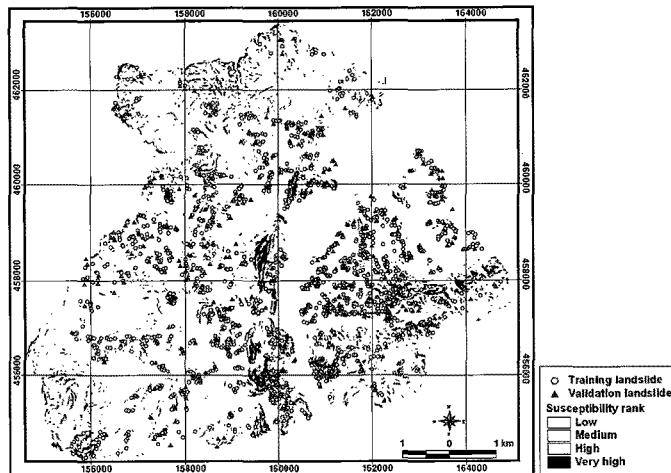


Fig. 6. Landslide susceptibility map based on artificial neural network.

최대 반복 횟수는 5,000번, 학습률은 0.01로 설정하여 요인들의 상대적 가중치를 계산하였다. 계산된 가중치를 각 요인에 부여하여 연구지역 전체에 대한 산사태 취약성도를 작성하였다(Fig. 6). Table 2은 10번의 무작위 샘플에 대한 각각의 가중치 결과로서, 본 연구에서는 10회의 평균값을 각 요인의 대표값으로 정하고, 이의 해석을 편리하게 하기 위해 각 평균값 중에서 가장 작은 값으로 나누어 주었다. 그 결과 각 요인의 가중치는 경사방향, 경사, 토양배수, 임상, 경급, SPI, 영급, 소밀도, 지형, 곡률, 모재, 유효토심, 단층, 토지 특성, 지질, TWI, 토질 순으로 높게 나타났다. 이중에서 경사방향과 경사의 가중치는 1.503과 1.429로 다른 요인들에 비해 가중치가 높았다. 그러므로 이 두 요인이 산사태 발생에 가장 중요한 요인으로 고려된다. 요인들의 상대적 가중치를 각 요인에 부여하여 도출된 취약지수는 시각적 해석을 위해 상위 5%, 10%, 15%, 70%로 등급화하여 산사태 취약성도를 작성하였다(Fig. 6).

6. 결과 검증

인공신경망을 이용하여 도출된 산사태 취약지수는 추정(assessment)값에 해당되므로 검증이 필요하다. 이를 위해 Success Rate Curve(SRC) 방법을 이용하였다. SRC 방법은 산사태 취약지수 값을 그대로 사용하지 않고 상대적 순위를 10%별로 값을 재분류하여 각 범위

안에 포함되는 기존 산사태 발생 위치의 셀 수를 누적 계산하여 상대적 비율을 계산한다. 상대적 비율을 사용할 경우, 연구지역 전체에서 차지하는 비율은 100%로 항상 같기 때문에 서로 다른 지역의 분석 결과와 비교하기 수월하며, 다른 모델을 사용하여 계산된 결과와 비교할 수 있다.

Fig. 7의 SRC는 산사태 취약성도의 검증 그래프이다. 그래프의 X축은 산사태 취약지수를 상위 퍼센트로 10 등급화한 값이고, Y축은 검증용 산사태 수의 누적 퍼센트 등급값이다. 예를 들어, Y축의 값이 1%일 때 X축의 값이 100%라면 산사태 취약성도에서 취약성이 높게 나타난 1%의 픽셀 안에 산사태가 모두 속한다는 것을 의미한다. 보다 정량적인 검증을 위해 AUC(Area Under

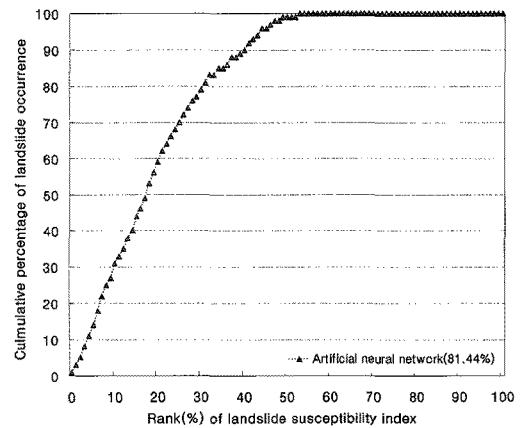


Fig. 7. Success rate curve of landslide susceptibility map.

the Curve)방법을 이용하였는데(Fig. 7), 이 방법은 위의 SRC 그래프의 아래 면적을 구하는 것으로써 X축과 Y축을 1:1로 곱하면 그 SRC 아래의 면적을 구할 수 있다. 최대 예측 정확도는 10,000의 면적을 갖고, 이 면적이 넓을수록 산사태 취약성도의 예측 정확도가 높음을 의미한다. 그 결과 취약지수의 상위 30% (Very high ~ Medium) 내에 분포하는 산사태는 79%로 나타났고, 전체적으로 산사태 취약성도는 81.44%로 높은 예측 정확도를 보였으며, 취약지수의 최소값은 0.557, 최대값은 0.9793, 평균값은 0.7625, 표준편차는 0.2205로 나타났다.

7. 결론 및 토의

본 연구에서는 2006년 태풍 에워니아, 빌리스, 개미로 인하여 발생한 진부면 지역의 산사태는 디지털 항공 사진을 이용하였고, 인공신경망을 이용하여 산사태 발생 요인들에 대한 가중치 결정과 산사태 취약성도를 도출하였다. 인공신경망 분석시 훈련지역은 산사태 발생 지역과 경사가 0도인 지역을 선정하여 각 요인별 가중치를 계산하였다. 그 결과 경사방향과 경사 요인의 가중치는 1.503과 1.429로 나타났다. 다른 요인의 가중치는 1.1355이하로 경사방향과 경사에 비해 낮게 나타났다. 이와 같이 인공신경망의 학습방법에 의해 얻어진 각 요인들의 가중치는 산사태와 관련된 요인들의 상대적 중요도를 파악할 수 있었다. 계산된 가중치를 각 요인에 부여하여 산사태 취약성도를 작성 후 분석에 사용하지 않은 산사태 위치로 검증해본 결과 81.44%의 높은 예측 정확도를 보였다.

서비스되는 디지털 항공사진을 이용한 산사태의 위치 선정은 기존의 현장조사 방법에 비해 시간, 비용, 인력을 최소화하여 효율적으로 수행되었기에 전국적으로 확대 적용 할 수 있다. 또한 전국의 산사태 취약성도를 도출 할 수 있음에 따라 본 결과는 향후 국가의 토지이용정책의 의사결정 자료로서 활용될 수 있을 것이다.

사사

이 논문은 한국지질자원연구원의 기본 연구사업인 "GIS 기반 국토지질정보시스템 실용화 기술 개발" 과제의 일환으로 수행되었다.

참고문헌

- 김철민, 2008. 산림자원정보 인벤토리 구축과 활용. 농업환경자원 인벤토리 구축과 활용 전략 국제 워크숍, 농촌진흥청, 6월 26일, 320 p.
- 워터저널, 2007. 물로 인한 재해를 예방하자. 6월호.
- 태백산지구지하자원조사단, 1962. 태백산 지구 지질도 (1:50,000), 하진부 도록, 대한지질학회.
- Alman, D. H. and N. Liao, 2001. Overtraining in Back-Propagation Neural Networks: A CRT Color Calibration Example, COLOR research and application, 27: 122-125.
- Beven, K. J. and M. J. Kirkby, 1979. A physically based, variable contributing area model of basin hydrology, Hydrological Sciences Bulletin, 24: 43-69.
- Carrara, A., M. Cardinali, R. Detti, F. Guzzetti, V. Pasqui, and P. Reichenbach, 1991. GIS techniques and statistical models in evaluating landslide hazard, Earth Surface Processes and Landforms 16(5): 427-445.
- Hines, J. W., 1997. Fuzzy and Neural Approaches in Engineering, John Wiley and Sons, New York, pp. 209.
- Johnes, D. K., D. Brunsden, and A. S. Goudie, 1983. A preliminarily geomorphological assessment of part of the Karakoram highway, The Q. J. of Engineering Geology, 16: 331-355.
- Lee, S., 2005. Application of logistic regression model and its validation for landslide susceptibility mapping using GIS and remote sensing data, International Journal of Remote Sensing, 26: 1477-1491.

- Lee, S., 2007a. Landslide susceptibility mapping using an artificial neural network in the Gangneung area, Korea, International Journal of Remote Sensing, 28: 4763-4783.
- Lee, S., 2007b. Application and verification of fuzzy algebraic operators to landslide susceptibility mapping, Environmental Geology, 52: 615-623.
- Lee, S., J. Choi, and K. Min, 2002. Landslide susceptibility analysis and verification using the Bayesian probability model, Environmental Geology 43(1-2): 120-131.
- Lee, S., J. W. Choi, and I. Woo, 2004. The effect of spatial resolution on the accuracy of landslide susceptibility mapping: a case study in Boun, Korea, Geosciences Journal, 8: 51-60.
- Lee, S., J. H. Ryu, K. Min, and J. S. Won, 2003. Landslide susceptibility analysis using GIS and artificial neural network, Earth Surface Processes and Landforms, 28(12): 1361-1376.
- Lee, S., J. H. Ryu, J. S. Won, and H. J. Park, 2004a. Determination and application of the weights for landslide susceptibility mapping using an artificial neural network, Engineering Geology, 71(3-4): 289-302.
- Lee, S., Ryu, J. H., Lee, M. J., and J. S. Won, 2006. The application of artificial Neural networks to landslide susceptibility mapping at Janghung, Korea, Mathematical Geology, 38: 199-220.
- Lee, S., J. H. Ryu, and I. S. Kim, 2007. Landslide susceptibility analysis and its verification using likelihood ratio, logistic regression, and artificial neural network models: case study of Youngin, Korea, Landslides, 4: 327-338,
- Lessing, P. and R. B. Erwin, 1977. Landslides in West Virginia. In: Coates, D.R. (Ed.), *Landslides*. Geological Society of America, Boulder, CO, Reviews in Engineering Geology, 3: 245?254.
- Moore, I. D., R. B. Grayson, and A. R. Ladson, 1993. Digital terrain modeling: a review of hydrological, geomorphological, and biological applications. In: Beven KJ, Moore ID (eds) *Terrain analysis and distributed modeling in hydrology. Advances in hydrological processes*. Wiley, Chichester.
- Ohlmacher, G. C., 2007. Plan curvature and landslide probability in regions dominated by earth flows and earth slides, Engineering Geology 91: 117-134.
- Paola, J. D. and R. A. Schowengerdt, 1995. A review and analysis of backpropagation neural networks for classification of remotely-sensed multi-spectral imagery, International Journal of Remote Sensing, 16: 3033-3058.
- Schneider, S. and M. Gruber, 2008. Radiometric quality of Ultracam-X images., In: Proceedings of ISPRS Congress, Beijing, p. 539.
- Van Westen, C. J. and M. T. J. Terlien, 1996. An approach towards deterministic land slide hazard analysis in GIS: A case study from Manizales (Colombia), Earth Surface Processes and Landforms 21(9): 853-868.
- Wilson, D. J. and J. C. Gallant, 2000. Digital terrain analysis. In: Wilson DJ, Gallant JC (eds.) *Terrain analysis: principles and applications*, Wiley, New York, 1-27.