

자기 조직화 신경망을 이용한 위성영상 분류

진영근[✉]
청양대학 전산학과
yjin@chongyang.ac.kr

Classification of Satellite image by Self-Organizing Maps

Young-Goun Jin[✉]
Dept. of Computer Science, Chongyang College

요약

위성이 보내어오는 영상의 량은 인간이 일일이 실시간으로 검색할 수 없을 정도의 방대한 양이다. 그러므로 위성이 보내어오는 영상을 자동적으로 빠른 시간내에 분석하기 위하여 원폐스로 성질이 유사한 영역을 묶어서 분류하는 알고리듬이 필요하다. 본 연구에서는 자기조직화 신경망(SOM)을 인공위성 영상을 원폐스에 분할할 수 있도록 학습방법을 개선하였으며 개선된 SOM 알고리듬이 같은 원폐스 알고리듬인 온라인 K-means과 비교하여 유효함을 알 수 있었다.

1. 서론

인공위성이 촬영한 영상은 기후, 환경, GIS, 농업, 지질학 등 다양한 분야에 응용되고 있다. 이러한 영상들은 유사한 성질을 가진 영역으로 분류하므로써 더 쉽게 인간에게 유용한 정보를 제공할 수 있다. 선형 CCD를 이용한 영상 촬영에 있어서 항공영상의 경우 촬영지면과의 직하점(nadir) 거리가 수km에서 수십km정도이기 때문에 촬영범위가 비교적 좁고 분해능도 좋으나 넓은 범위의 영상을 획득하기 위하여 광각렌즈를 사용하는 경우 항공기의 nadir 방향의 영상이 아닌 전후 또는 전후 또는 측면의 영상을 획득한 경우 원근에 의한 동일화면상의 각 픽셀에 대한 분해능의 차이가 심해지므로 이에 대한 보정을 해야하나 위성영상의 경우 촬영지면과 위성과의 직하점 거리가 수백km에서 수천km이므로 분해능은 항공영상에 비하여 조금 떨어지나 촬영 범위 폭 및 거리를 길게 할 수 있다. 그렇기 때문에 대부분의 경우 인공위성이 하루에 발생시킬 수 있는 영상데이터의 양은 매우 많다. 예를 들어 중급 지구 영상을 제공하는 NASA의 MODIS 위성 두 대가 하루에 찍어 내려보내는 영상의 분량은 약 1,902GB 정도이다. 또 일반에게 잘 알려진 landsat 위성은 하루에 약 122GB의 데이터를 발생시킨다. 이러한 많은 데이터를 사람이 일일이 실시간 또는 오프라인으로 검색하여 유효한 정보를 찾아내기는 매우 어렵고 또 많은 인원과 경비가 소요된다.

그러므로 주요 관심지역의 영상외에서 유용한 정보를 얻기는 어려우므로 영상처리시스템과 데이터 마이닝 및 지식기반 시스템을 이용하여 자동적으로 인공위성 영상으로부터 주요정보를 추출하려는 노력이 경주되고 있다. 인공위성 영상에서 분류하고자 하는 또는 찾고자 하는 물체에 따라 적용되는 방법은 다르다. 일반적으로 지형을 찍은 인공위성의 영상데이터를 지형의 형질 및 특질에 따른 분류를 수행할 경우에 사용하는 방법으로는 통계적 클러스터링 방법에 속하는 Principal Component Analysis, Minimum Distance Classification, Maximum Likelihood(ML) Classification, 신경망을 이용한 방법 등이 많이 사용된다. 예를 들면 미국 NASA에서는 ML 방법의 단순화된 형태인 K-means 방법^{[1][3]}을 사용하여 landsat이 찍은 열 영상의 지형의 형질에 따른 분류를 수행하고 있으며 온라인 K-means를 사용하여 온라인으로 데이터를 분류하는 작업도 시도하고 있다. 본 논문에서 제시하는 방법은 신경망을 이용하는 방법으로 여러 가지 신경망 중에 Kohonen의 자기조직화(Self-Organizing Maps) 신경망을 사용한다^{[2][3]}. SOM 신경망은 클러스터링 기능이 우수한 신경망으로 인공위성 영상 분류시 교사/비교사 (Supervised/Unsupervised) 분류에 모두 적용될 수 있는 알고리듬이다.

그러나 이러한 분류에 사용되기 위해서는 초기 수령도를 높여 줄 필요성이 있으며, 학습범위상수 및 학습비율상수를 적절히 제어할 필요성이 있다. 본 논문에서는 이러한 상수들의 적절한 제어방법에 대하여 제시하며 제시된 방법을 인공위성 영상분할에 적용시켰으며 제시된 방법의 유효성을 알 수 있었다.

2. 온라인 K-means

일반적으로 K-means 클러스터링 알고리듬은 데이터 분류에 있어 Maximum-Likelihood(ML) 방법의 단순화된 형태이며 절대적 수렴에 대한 보장도 없다. 그리고 알고리듬의 원활한 수행을 위하여 초기에 클러스터링해야 할 개수를 미리 정해야하고 또 클러스터의 초기 값에 따라 클러스터링 된 결과의 수렴성이 달라지는 특성이 있다. K-means 알고리듬은 반복 수행을 거치기 때문에 전체데이터를 가지고 있어야 하므로 off-line 데이터를 클러스터링하도록 되어 있다. 그러나 분류해야 할 데이터의 양이 많거나 실시간 데이터의 경우 단일 패스로 분류하게 하기는 어렵다. 그러나 승자 클러스터를 학습시키는 과정을 변경하여 단일 패스로 데이터를 클러스터링 하도록 할 수 있다. ϵ 는 학습 비율로서 학습이

$$\Delta z_i = \epsilon(x_i - z_i)$$

진행될수록 그 값이 적어진다. on-line K-means의 수행은 우선 클러스터의 개수와 그 중심들을 초기화한 후 승자를 클러스터를 구하고 그 클러스터의 중심을 움직여서 개선시키며 더 이상의 입력이 없을 때까지 반복한다.

3. 자의식을 가진 SOM

SOM은 Kohonen에 의해 제시된 비교사 학습 신경망으로 다차원의 입력 데이터 공간에서 유사한 특성을 가진 데이터들이 인접하도록 전사(mapping)시키는 기능이 뛰어난 알고리듬이다. SOM은 출력노드와 입력사이의 거리가 최소되는 출력노드를 승자로 선정한다는 방식에 있어서는 K-means와 매우 유사한 관계가 있다. 그러나 K-means에서는 승자 클러스터만을 다시 학습시키는 반면에 SOM은 그 주변까지도 학습을 수행한다는 차이점이 있다. 또 K-means는 초기 입력으로 클러스터의 개수 및 초기 값들이 사용하여 구한다. SOM에서 학습 비율 상수는 학습이 진행될수록 그 값이 줄어드는 양의 실수이며. 영향을 받는 주변범위도 학습을 진행할수록 범위가 줄어든다. 주변범위는 주변학습 합수로 표현될 수 있으며 통상 일차원 선형 합수 또는 가우시안 합수를 사용한다. 그러므로 SOM을 사용하기 위해서는 학습 진행률을 조정하는 상수와 주변범위를 학습 횟수마다 적절히 줄여 주어야 하며 선택치의 적절도에 따라 학습 진행시 안정된 영역으로 수렴하거나 국지 안정 영역에 빠질 수 있다. SOM도 반복 학습을 시켜야 하므로 실시간 또는 온라인으로 들어오는 데이터를 학습, 탐색하는데 적용하기가 어렵다. 그러므로 온라인에도 적용 가능하도록 SOM의 학습 성능을 개선시켰다.

본 논문에서 제시하는 자의식을 가진 개선된 SOM은 SOM의 기본적인 골격을 유지하며 학습 진행률 조정 상수를 변경하여 SOM이 hard C-means와 유사한 기능의 클러스터링툴로 작용하도록 한다. 그러기 위해서는 SOM의 출력노드들은 각각의 자신의 우승 횟수를 기억할 수 있는 메모리 즉 자의식 H_i 를 가진다. 개선된 SOM의 수행은 다음과 같다.

1단계: weight 벡터 w_i 를 임의의 값으로 초기화시킨다. H_i 는 1로 초기화한다.

2단계: 입력 벡터 x 와 모든 weight 벡터 w_i 중에 가장 유사한 승자 노드를 구한다.

3단계: 학습방법은 승자노드와 그 주변 노드를(주변 학습 합수가 T_h 보다 큰 경우) 다음 식으로 개선 시킨다.

$$\text{if } Q_c(i) > T_h$$

$$w_i = (w_i * H_i + x) / (H_i + 1)$$

4단계: 다음 입력벡터가 있으며 단계2로 가서 반복하고 없으면 종료한다.

개선된 Kohonen SOM은 각 출력노드가 자신의 우승회수를 기억하는 자의식(consciousness)을 가지고 있으므로 자신의 우승회수가 증가하면 할수록 새로운 우승에 의한 자기 학습 영향의 범위를 줄어들이는 구조를 보인다. 즉 가능한 자기의 기억을 유지하도록 하여 기존의 Kohonen SOM의 학습에 따라 줄어드는 학습 비율 상수를 대체하도록 한다. 그러므로 on-line 학습에 적용하기 위한 개선으로 인하여 SOM의 학습횟수에 따라 변경되는 학습비율 상수가 제거된다. 대용량의 데이터를 분류할 경우 초기 오류는 무시할 수 있을 정도로 적어지므로 대량의 온라인 데이터를 분류할 경우 데이터 수가 증가하면 분류오차는 줄어든다. 또 자의식의 영향을 확대하면 주변 학습 범위까지 자의식으로 제어할 수 있다.

4. 실험

본 논문에서 제시한 자의식을 가진 개선된 SOM 클러스터링의 on-line 데이터 탐색 성능을 검증하기 위하여 시뮬레이션을 수행하였다. 시뮬레이션에 사용된 입력 데이터로는 landsat 인공위성에서 수신된 다색채널의 영상 데이터를 적용시켜 보았다. 이 데이터는 클러스터링 또는 데이터 분류기의 성능을 평가하기 위해 사용되는 표준 데이터로 출처는 ESPRIT(European Strategic Program for Research and development in Information Technology) 기초연구인 ELENA 보고서이다.^{[4][5]} 이 데이터의 원 영상은 호주 지역을 찍은 landsat 위성의 다색 채널 영상으로 크기는 82*100이고 채널수는 가시영역 2 채널 및 적외선 영역 2 채널로 총 4개의 채널이 있다. 7 가지의 토지 형질을 구분하는 것으로, 전문가의 현지 답사에 의해 7가지 형질로 분류되었으나 6번째 형질은 확인의 불확실성으로 인해 제외되고 실제는 6개의 형질 클러스터로 분류하는 것이다.

하나의 데이터는 3×3 픽셀 영상 및 4색 채널로 구성되어 총 36개 차원을 구성하며, 전체 분류해야 할 데이터 개수는 6,435개로 그중 4,435개가 학습용으로 2,000개가 분류용으로 사용되나 본 실험에서는 전체 데이터 6,435개를 온라인 K-means와 개선된 SOM으로 분류시켰다. 온라인 K-means 분류의 경우 초기 값은 6,435개의 데이터를 각각의 클래스 또는 클러스터 즉 토질형태에 따라 평균을 취한 값으로 하였다. 이러한 초기 값에도 불구하고 클래스 상호간의 간섭이 심하여 분류율이 좋지 않게 나타났으며 것을 볼 수 있다. 첨부된 k-NN 분류는 ELENA 보고서에서 인용된 것으로 오프라인에서 반복 최적화 시켜 분류한 값이다. 본 논문에서 제시한 개선된 SOM에서는 출력노드의 크기는 13×13 이고 상수 T_h 는 0.5이다. 출력노드에서의 최종 6개 분류군 선정은 각 클래스 평균으로부터 Minimum Distance 방식으로 선정하였다. 개선된 SOM에서는 샘플범위내의 임의의 값으로 초기값을 정했기 때문에 초기 수렴 단계에서 오차가 많으나 학습과 동시에 분류가 진행될수록 오차는 줄어들었다. 제시된 임의 초기값 분류 비율은 100회 이상의 수행의 평균을 하여 임의 초기값에 의한 편차를 줄였다. 그러므로 본 논문에서 제시한 방법이 비록 오프라인 최적화인 k-NN 방법보다 분류율은 떨어지지만 온라인 K-means보다 성능이 뛰어남을 알 수 있었다. 다음 표는 세가지 분류 방법을 사용한 평균 분류치를 나타낸다.

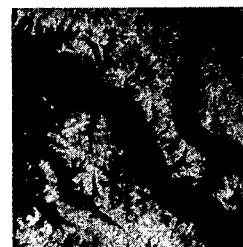
<표> 분류 방법별 평균 데이터 분류

분류방법	분류비율(%)
k-NN(최적화, 오프라인)	91.13
온라인 K-means(최적초기값)	70.05
온라인 SOM(임의초기값)	81.35
온라인 SOM(평균초기값)	83.78

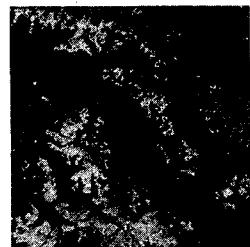
다음은 landsat 위성이 TM(Thermal Mapper)촬영한 한국의 남서해안 지역으로 해상도가 25m 인 영상을 샘플 분류한 결과를 보여준다. TM의 5,4,3 채널을 의사 칼라(R,G,B)로 하여 분류하였으며 데이터단위는 픽셀단위로 하여 총데이터개수는 499×499 이다. 출력노드의 크기는 13×13 으로 하고 상수 T_h 는 0.5로 하였다. 출력노드에서 6개의 분류군 노드를 선정하고 Minimum Distance 방식으로 나머지 노드들을 할당하였다. 해당 지형의 전문적인 답사에 의한 정확한 분류는 아니지만 원판스에 의한 지형의 형질을 분류한 결과는 다음 표와 같다.

<표> 남서해안 영상의 예측분류

예측분류	비율(%)
물(담수, 해수)	32.1
논경지, 얕은 물	21.3
도로, 재방 또는 토지	15.9
초지, 풀등	13.3
바위, 황토등	6.7
수림, 녹지대등	10.7



a) 원영상



b) 온라인분류된 영상

<그림> landsat에 의한 남서해안영상

5. 결론

인공위성에서 내려오는 영상데이터를 자동적으로 해석하기 위한 선행연구로 자기조직화신경망의 학습 방법을 개선시켜 유사 실시간에 위성 영상을 의미있는 영역으로 분류할수 있는 원판스 분류 알고리듬을 제시하였다. 오프라인 방법에 비하여 분류의 정확도는 아직 많이 뛰어지지만 온라인 K-means에 비해서는 분류 성능이 뛰어남을 알수 있었다. 분류의 정확도를 높이기 위하여 최적 초기값 선정문제와 최종 분류군 선정문제에 대한 연구가 앞으로 지속되어야 한다.

6. 참고문헌

1. The Remote Sensing Tutorial, on-line book <http://rst.gsfc.nasa.gov/Start.html>
2. Kohonen,T., "Self-Organization and Associative Memory" Springer-Verlag, Berlin, 3rd Edition, 1989.
3. Zhang and Li,Y. "Self-organizing map as a new method for clustering and data analysis" Preceedings of IJCNN'93, 1993. pp.2448-2451
4. Jutten,C. Deliverable R3-B4-P Task B4 : Benchmarks, Tech. Rep., ElenaNervesII "Enhanced Learning for Evolutive Neural Architecture", ESPRIT-Basic Research Project No. 6891 June 1995.
5. Jutten,C. Deliverable R3-B1-P Task B1 : Databases, Tech. Rep., ElenaNervesII "Enhanced Learning for Evolutive Neural Architecture", ESPRIT-Basic Research Project No. 6891 June 1995.