

## SOM 기반 시공간 데이터 마이닝 시스템

강주영\*, 이봉재\*, 송재주\*, 신진호\*, 용환승\*\*,

\*한국전력 전력연구원 전력정보기술그룹

\*\*이화여자대학교 컴퓨터학과

e-mail:jykang@kepri.re.kr

## SOM-based Spatio-Temporal Data Mining System

-Juyoung Kang\* Bongjae Lee\* Jaeju Song\* Jinho Shin\* Hwanseung Yong\*\*

Power Information Technology Group, KEPRI\*

Dept. of Computer Science and Engineering, Ewha Womans University\*\*

### 요약

데이터 양이 급증함에 따라 축적된 데이터로부터 의미있는 지식을 추출해 내고자 하는 데이터 마이닝에 대한 연구가 활발하게 진행되어 왔다. 특히 최근, 환경이 이동 분산화 되어감에 따라 감시·모니터링 시스템, 기상 관측 시스템, GPS 시스템과 같은 다양한 용용 시스템으로부터 방대한 양의 시공간 데이터가 발생하게 되었고, 이를 효율적으로 분석하고자 하는 시공간 데이터 마이닝 연구에 대한 관심이 더욱 높아지고 있다. 기존의 데이터 마이닝 기법의 경우 문자나 숫자 데이터를 대상으로 최적화 되어있기 때문에 시·공간 속성을 동시에 가지는 데이터를 분석하기에는 한계가 있는 것이 사실이다. 본 논문에서는 SOM(Self-Organizing Map)을 적용하여 시공간 클러스터링 모듈을 개발하고, 개발된 모듈의 성능 및 클러스터링 정확성을 다른 세 가지 군집분석 알고리즘과 비교, 분석하였다. 또한 가시화 모듈을 개발하여 입력 데이터의 특성과 결과를 더욱 정확하게 분석할 수 있도록 하였다.

### 1. 서론

자연과학 관측 시스템에서 오랜 기간동안 축적된 데이터나 이동 분산화 되어가는 환경에서 발생하는 시공간 데이터를 기반으로 지식탐사 프로세스의 핵심인 데이터 마이닝을 적용하여 효율으로 분석을 수행하고자 하는 시공간 데이터 마이닝에 대한 연구가 활발히 진행되고 있다. 그러나 기존의 마이닝 알고리즘들은 문자나 숫자를 기반으로 하기 때문에 시공간 데이터 분석에 적용하기에는 성능과 정확도 면에서 한계를 가지는 것이 사실이다[1]. 또한 시공간 데이터 마이닝의 경우 지식 탐사의 절차와는 상관없이 입력의 형태나 속성, 결과의 의미에 대한 해석 등이 더욱 중요하게 다루어져야 한다[2]. 기존의 시공간 데이터 마이닝 관련 연구는 주로 K-means, SOM(Self-Organizing Map), 응집 계층(Agglomerative Hierarchical) 알고리즘과 같은 문자·숫자 기반의 군집분석 알고리즘들을 기반으로 하고 있는데 [3,4], 이러한 기법들을 시공간 데이터에 적용하는

경우 실제 성능은 어느 정도인지, 최적의 알고리즘을 선택하기 위한 기준은 무엇인지 등에 대한 연구는 미흡한 실정이다. 따라서 더욱 정확한 결과를 얻기 위해서는 기존의 기법들을 적용함에 있어서 시공간 특성에 따라 최적의 알고리즘을 선택하기 위한 객관적인 기준을 제시할 필요가 있다.

본 논문에서는 폐탄 인식과 클러스터링 능력이 뛰어나다고 알려진 SOM을 기반으로 시공간 클러스터링 시스템을 개발하고, 구현된 모듈의 성능을 K-means, Average Linkage, Ward의 세 가지 알고리즘과 균질도, 분리도, 반면영상 너비, 정확도의 네 가지 기준을 기반으로 비교한다. 또한 더욱 정확한 결과 분석을 위해 가시화 모듈을 개발하고 이를 이용해 클러스터링 결과를 분석한다.

본 논문의 구성은 다음과 같다. 1절의 서론에 이어 2절에서는 구현된 SOM 기반 시공간 데이터 마이닝 시스템에 대해 소개한다. 3절에서 시스템의 성능 평가 결과를 기술한 후, 4절에서 결론을 맺는다.

## 2. SOM 기반 시공간 데이터 마이닝 시스템

본 논문에서는 SOM을 기반으로 시공간 클러스터링 시스템을 구현하고 이의 성능을 분석하였다. 개발된 시스템은 [그림 1]과 같이 크게 데이터 생성기, 데이터베이스, 전처리 모듈, SOM 기반 클러스터링 모듈, 가시화 모듈로 구성된다.




그림 1 시스템 구성도

### 2.1 시공간 데이터 생성기

본 논문에서는 시공간 데이터 처리에 필수적인 사전 처리의 부담을 덜고 입력 데이터의 속성을 평가 목적으로 알맞게 설정하기 위하여 실제 응용 시스템 데이터가 아닌 GSTD(Generate Space-Temporal Data) 시공간 데이터 생성기를 이용하였다. GSTD는 시공간 데이터베이스 통합 벤치마킹 시스템으로써 웹 상에서 다양한 형태와 움직임의 시공간 데이터를 XML 형태로 생성하도록 지원한다[5].

### 2.2 데이터 전처리 모듈

XML 형태의 원시데이터를 SOM에 적용하기 위해서는 다차원 벡터로 벡터화하는 작업이 필요하다.  $n$  프레임 동안 움직인 객체  $i$ 는 다음과 같이  $n$  개의 흐름벡터(Flow Vector)의 집합  $Q_i$ 로 표현된다.

$$Q_i = \{f_1, f_2, f_3, \dots, f_n\}$$

흐름벡터는 다음과 같은 요소로 이루어진다.

$$f = (x, y, dx, dy)$$

- $x, y$  : 특정 시간에서의  $x, y$  좌표값
- $dx, dy$  : 객체가 특정시각에 각 축으로 움직인 상대 순간속도

전처리 모듈에서는 각각의 연속되는 원시 데이터의 위치 좌표를 비교하여 상대 순간속도  $dx$ 와  $dy$ 를 계산하고 다음과 같은 다차원 흐름 벡터 형태로 변환하여 데이터베이스 내에 저장한다[표1].

### 2.3 SOM 기반 클러스터링 모듈

SOM은 Kohonen이 제안한 신경망 기반의 알고리즘으로 해부학적 이론에 근거하여 인간의 두뇌 구

[표1] 전처리 후의 시공간 데이터 테이블

필드명	데이터 타입	설명
ID	NUMBER(4,0)	이동 객체의 ID
TIME	NUMBER(18,6)	이동 객체가 출격한 시각(타임스탬프)
X	NUMBER(18,5)	이동 객체의 위치 - x 좌표 값
Y	NUMBER(18,5)	이동 객체의 위치 - y 좌표 값
DX	NUMBER(18,5)	이동 객체가 x축으로 움직이는 순간 속도
DY	NUMBER(18,5)	이동 객체가 y축으로 움직이는 순간 속도
CLUSTER	NUMBER(4,0)	결과 클러스터 번호

조를 모델링 한 방법이다. 즉, 인접한 출력노드들은 비슷한 기능을 수행할 것이라고 예측하여 입력노드와 가장 가까운 출력노드를 뿐만 아니라 그 이웃노드들도 함께 학습시키는 일종의 경쟁 학습 알고리즘이다[6]. 알고리즘의 수행순서는 다음과 같다.

- 1) 클러스터 K의 수를 초기화 한다.
- 2) K개의 출력노드를 위상공간 내에 배치한다.
- 3) 학습률을 초기화한다. (학습률은 0과 1사이의 값을 가지며, 시간이 지남에 따라 감소한다.)
- 4) 새로운 입력벡터를 입력노드에 제시한다.
- 5) 입력벡터와 모든 출력노드들과의 거리(Euclidean)를 계산하여 최소 거리의 승자노드를 찾는다.
- 6) 2번으로 가서 반복한다.
- 7) 훈련횟수만큼 네트워크를 훈련한 후 출력노드의 최종 가중치와 결과클러스터 번호를 저장한다.

### 2.4 가시화 모듈

본 논문에서는 시공간 데이터의 특성과 클러스터링 결과를 더욱 쉽고 정확하게 나타내기 위하여 가시화 모듈을 구현하였다. 구현된 가시화 모듈의 특성은 다음과 같다.

- 2차원 좌표상에 입력 데이터 가시화
- 입력에 대한 결과 클러스터 가시화
- SOM 네트워크의 출력노드 표시
- 균질도, 분리도, 반면영상너비 값 계산
- 객체 및 클러스터 정보조회
- 특정 데이터의 이동 궤적 가시화




그림 2 가시화 모듈

### 3. 성능 평가

#### 3.1 실험 데이터

각각의 실험 데이터는 입력 데이터의 방향, 속도, 그리고 방향·속도의 복합 속성에 대해 알고리즘의 성능을 평가할 수 있도록 생성하였다. 첫 번째 그룹은 방향 속성에만 차이를 준 D1~D6, 두 번째 그룹으로 속도에만 차이를 준 데이터세트 D7~D16, 마지막으로 복합 시공간 속성을 지닌 이동 객체 그룹인 D17의 세 종류 데이터를 생성하였다. 각 데이터 세트는 2개의(D17의 경우 4개) 이동 객체 그룹들로 이루어져 있으며, 각 그룹 당 객체 수는 50개로 설정하였다. 각 데이터 세트의 특징은 다음과 같다.

[표2] 실험 데이터의 시공간 속성

데이터 세트번호 (D1-D17)	방향 차이			속도 차이			방법 + 속도 불규칙한 움직임	
	90도 75도 60도 45도 30도			10cm/s 0.1cm/s				
	출발점	도착점	D1 D2 D3 D4 D5	D7~D16	D17			
			D6					

#### 3.2 성능 평가 기준

클러스터링의 성능 평가 즉 유효성 검사(validation)란 수치적, 객관적인 방식으로 클러스터 분석의 결과를 평가하는 작업이다. 일반적으로 클러스터링의 결과를 평가하는 방법은 크게 외적 기준 분석과 내적 기준 분석의 두 가지로 나뉜다. 외적 기준 평가는 클러스터링의 결과를 대상 데이터를 분할하는 또 다른 최적기준(Gold Standard)과 비교하는 작업이고, 내적 기준 평가는 입력 데이터의 정보를 기반으로 입력과 결과 사이의 적합성을 평가하는 방법이다. 본 연구에서는 기준의 연구를 기반으로 다음과 같은 네 가지 평가 기준을 선정하였다[7,8].

##### ● 균질도(Homogeneity)

균질도는 클러스터의 중심점과 그에 속하는 점들 간의 평균 거리로 클러스터 내부의 분산을 나타내며 클수록 클러스터링이 잘되었다고 판단한다.

$D$ 는 거리함수,  $P_i$ 는  $i$ 번째 점,  $C(P_i)$ 는  $P_i$ 가 속한 클러스터의 중심점,  $N_{point}$ 는 전체 점의 수이다.

$$H_{ave} = \frac{1}{N_{point}} \sum_i D(p_i, C(p_i))$$

##### ● 분리도(Separation)

분리도는 클러스터의 중심들 간의 평균 거리로 클러스터 사이의 분산을 나타내며 수치가 작을수록 클러스터간의 분할이 명확하다고 판단한다.

$C_i$ 와  $C_j$ 는  $i$ 번째와  $j$ 번째 클러스터의 중심점,  $N_{ci}$ 와  $N_{cj}$ 는  $i$ 번째와  $j$ 번째 클러스터에 속한 점의 수이다.

$$S_{ave} = \frac{1}{\sum_{i \neq j} N_{ci} N_{cj}} \sum_{i \neq j} N_{ci} N_{cj} D(C_i, C_j)$$

##### ● 반면영상 너비(Silhouette Width)

반면영상 너비는 클러스터링 결과의 전체 질(quality)을 반영하며 클러스터들이 얼마나 컴팩트하며 분리가 잘 되었는가를 나타낸다. 수치가 클수록 클러스터링이 잘되었다고 판단한다.

$$s(i) = \frac{b(i) - a(i)}{\max \{a(i), b(i)\}}$$

$a(i)$ 는  $i$ 번째 점과 이 점과 같은 클러스터에 속한 점들과의 평균 거리이고  $b(i)$ 는  $i$ 번째 점과 가장 근접한 이웃 클러스터에 속한 점들의 평균 거리이다.

##### ● 정확도(Accuracy)


정확도는 각 데이터들이 예상 클러스터에 얼만큼 정확하게 클러스터링 되었는지 결과의 정확성을 나타낸다. 이 평가기준의 경우 예상 클러스터를 정확히 알고 있어야 평가가 가능하므로 실세계 데이터가 아닌 실험 데이터에만 적용 가능하다.

$$A_{ave} = \frac{1}{N_{point}} \sum_i A_i$$

$A_i$ 는  $i$ 번째 클러스터에 정확하게 클러스터링 된 점의 수이다.

#### 3.3 성능 평가 결과

본 논문에서는 구현된 SOM 기반 클러스터링 알고리즘의 성능을 K-means, 응집 계층 알고리즘 방법인 Average Linkage, Ward의 세 가지 알고리즘들과 비교하였다. 구현된 SOM 기반 알고리즘 이외의 나머지 세 알고리즘은 S-PLUS 통계 패키지의 마이닝 모듈을 이용하였다. 실험 데이터 D1~D6은 데이터의 방향 속성만을 달리한 그룹이다. 그럼 3에서 볼 수 있듯이 방향 차이가 75도인 경우(a), 모든 알고리즘이 두 그룹을 명확하게 구분하여 클러스터링하였지만, 차이가 30도로 줄어든 경우(b) SOM 모듈만 정확하게 클러스터링을 수행함을 알 수 있다.



(a) 두 그룹간 방향 차이 : 75도

(b) 두 그룹간 방향 차이 : 30도

그림 3 데이터 그룹 D2, D5의 클러스터링 결과

데이터의 속도 속성에만 차이를 준 데이터 세트들 중, 차이가 0.6cm/s와 0.3cm/s인 두 가지 경우에 대해 클러스터링 결과를 가시화 시켜 보았다. 그럼 4에서 볼 수 있듯이 이동 객체 그룹의 속도 차이가 적어질수록 구현된 SOM 모듈의 클러스터링 정확도가 다른 알고리즘들에 비해 우수함을 알 수 있다.




그림 4 데이터 그룹 D11, D14의 클러스터링 결과

그림 5와 6은 각각 데이터세트 D2~D5 그리고 D11, D13, D14에 대한 각 성능 평가 수치를 나타낸 그래프이다. 그림에서 볼 수 있듯이 균질도, 분리도, 반면영상너비와 같이 데이터의 시공간 특성을 고려하지 않는 외적 기준 평가 항목인 경우 데이터 세트 별로 성능에 거의 차이가 없다. 하지만 두 그룹간의 시공간 속성에 차이가 적은 D5나 D14 그룹과 같은 경우 클러스터링 결과의 정확도에 있어서 SOM기반 모듈이 다른 알고리즘보다 우수함을 알 수 있다.

#### 4. 결 론

본 논문에서는 SOM 기반 시공간 데이터 마이닝 시스템을 구현하고 그 성능을 다른 세 가지 알고리즘들과 비교 평가하였다. 균질도, 분리도, 반면영상 너비와 같이 입력 데이터의 시공간 속성을 고려하지 않는 외적기준에서는 K-means와 구현된 SOM 기반 모듈이 비슷한 성능을 보였으나, 가시화를 통해 데이터 속성에 따른 클러스터링 정확도를 확인한 결과 구현된 SOM 기반 모듈이 우수한 성능을 나타냄을 알 수 있었다. 이러한 결과를 기반으로 한 더욱 다양한 마이닝 알고리즘의 비교 연구나 시공간 속성에 따른 최적 알고리즘의 선택 기준을 제안하기 위한 지속적인 연구가 필요하다고 보인다.

#### 참고문헌

- [1] J.F. Roddick, and M. Spiliopoulou, "A bibliography of Temporal, Spatial and Spatio-Temporal Data Mining Research", SIGKDD Newsletter, 1999.
- [2] J.F. Roddick, and B. G. Lees, "Paradigms for Spatial and Spatio-Temporal Data Mining, Geogra




그림 5 알고리즘 별 성능 비교 (D2~D5)




그림 6 알고리즘 별 성능 비교 (D11, D13, D14)

phic Data Mining and Knowledge Discovery", Miller, H&J. Han, Taylor & Francis, London, 2001.

[3] N. Johnson and D. Hogg, "Learning the Distribution of Object Trajectories for Event Recognition", In Proc. of British Machine Vision Conference, vol. 2, 1995.

[4] J. Owens and A. Hunter, "Application of the Self-Organizing Map to Trajectory Classification", 3rd IEEE Int'l Workshop on Visual Surveillance (VS'2000), 2000

[5] Y. Theodoridis, J. R.O. Silva, and Mario A. Nascimento, "On the Generation of Spatiotemporal Datasets", In Proc. of the 6th Int'l Symposium on Large Spatial Database(SSD), 1999

[6] 김대주, 신경망 이론과 응용, 하이테크정, 2001

[7] Chen G, Jaradat SA, Banerjee N, Tanaka TS, "Evaluation and comparison of clustering algorithms in analyzing ES cell gene expression data", Statistica Sinica, pp.241-262, 2000

[8] Yeung, Haynor, Ruzzo: Validating Clustering for Gene Expression Data. Technical Report UW-CSE-00-01-01, 2000