

기업 도산 예측문제에서의 자기조직화지도 신경망의 활용

The Application of Self-organizing Map Neural Networks to Business Failure Prediction

김정섭, 한인구

한국과학기술원 테그노경영대학원

Email : kskim@msd.kaist.ac.kr

Abstract

We need to explore the inter-relation among financial data to diagnose the health of a firm. Predicting bankruptcy is a typical application.

In order to perform data reduction process of large financial database, we use self-organizing map neural network(SOM). SOM is an appropriate data-mining tool for exploring the characteristics of data, prior to any modeling because it can be used to explain the inter-relation of the data with their distinctiveness. Thus SOM makes it possible to acquire an intuitive understanding of structures of data.

Compared with conventional statistical techniques, for example, stepwise method or factor analysis, SOM can be used to summarize complex information in an effective and intuitive way.

Using SOM, We also explore time variant relationships between financial ratios, and the differences between failed and non-failed firms.

1. 서 론

최근 30 대 계열기업군 내 기업들을 포함한 많은 국내 기업들이 도산 내지는 도산정후를 보임에 따라, 기업 도산예측 연구의 중요성이 점차 커지고 있다. 도산예측에 대한 최근 연구들은 다양한 인공지능 기법들을 응용하여 새로운 예측모형을 제시하거나 여러 기법의 병렬적 사용(Hybridization)이나 심층적 통합(Integration)을 이용하여 적중률(Hit Ratio)을 높이는 방향으로 주로 이루어 졌다.

실제로 정확한 예측을 위해서는 각 기법에 서 필요로 하는 충분한 양의 데이터의 확보와 적절한 전처리(Preprocessing)과정, 그리고 변수 차원 감소(Data Dimensionality Reduction)를 위한 변수 선택 과정이 중요하다. 기존 연구에서는 전처리 과정으로 패턴 정규화를 주로 사용하고 있고, 변수선택과정으로는 요인분석(Factor Analysis)이나 단계적방식(Step-wise Method)방식 등 통계적 방법 들을 주로 이용해 왔다.

한편, 실무에서 여신 담당자들이 도산여부에 대한 예측모형 외에 도산 과정이나 도산 유형에 대한 분석모형에 대해서도 필요성을 지적하고 있지만, 이에 대한 연구가 거의 없는 실정이다.

본 논문은 정확한 도산예측 모형의 개발보다는 위에서 제기한 여러 논점들에 대해서 자기조직화지도 신경망(Self-Organizing Map Neural Network)을 활용하여 발견한 결과들을 제시하는데 목적이 있다.

본 논문의 구조는 먼저, 2절과 3절에서는 데이터 마이닝(Data Mining) 기법과 이 중 중요한 전처리 과정인 군집화 패턴 인식 방법에 대하여 각각 살펴본다. 4절에서는 변수 선택 문제에 대한 자기조직화지도 신경망의 활용, 5절서는 도산 징후 패턴 인식 문제에 대한 자기조직화지도 신경망의 활용에 대해서 각각 실제 재무 데이터를 이용하여 실험한 결과를 보고하고, 마지막 절에서는 결론 및 향후 연구 방향을 제시한다.

2. 데이터 마이닝

데이터 마이닝(Data Mining)은 지식발견(Knowledge Discovery)이라고도 하며, 대규모 데이터베이스에서 사전에 알지 못했던, 타당성있고 의사결정에 유용한, 이해 가능한 정보를 자동적으로 추출하는 과정으로, 추출된 정보는 조직의 주요 경영의사결정에 사용된다.

데이터 마이닝에 사용되는 기법들은 데이터의 상호관계(Data Inter-relation)을 탐색한다는 특징을 가지므로, 어느 기법을 사용할 것인가는 보유하고 있는 데이터의 성격에 따라 달라지게 된다.

일반적으로 사용되는 기법은 데이터 연상(Association), 순서 분석(Sequence-based analysis), 군집화(Clustering), 분류(Classification), 추정(Estimation), 퍼지논리(Fuzzy Logic), 유전자 알고리즘(Genetic Algorithms), 사례기반추론(Case-based Reasoning), 팩탈 변형(Factual-based Transforms) 그리고 인공 신경망(Neural Networks) 등이 있다(Moxon, 1996).

이 중에서 군집화는 데이터 마이닝 과정의 최초 단계에서 다른 기법의 전처리 과정으로 사용되고 있다.

3. 군집화 패턴 인식

패턴공간에 주어진 유한개의 패턴들이 무리를 이루고 있을 때 이러한 패턴집합을 군집(Cluster)라고 하며, 패턴간의 유사성이나 근접성을 이용하여 패턴들을 무리 지워 나가는 방법을 군집화 또는 클러스터링(Clustering)이라고 한다(김상운, 1995).

만일 대상 패턴들의 소속 클래스를 알 수 없다면, 각각의 패턴들로부터 이들의 패턴공간에서의 분포를 알아내는 군집화 작업은 자율적으로(Unsupervised) 패턴을 분류, 식별하는 과정이라고 할 수 있다.

군집화를 위한 방법으로는 통계적 방법과 인공 신경망 방법이 있다. 통계적 방법에는 크게 계층적(Hierarchical) 군집화 방법과 분할(Partitioning) 군집화 방법이 있다.

계층적 방법은 패턴간의 거리 또는 유사성을 기반으로 데이터를 군집하는 과정에서 군집수를 발견하는 방식이고 분할 방법은 군집수를 사전에 알고 있고 군집기준을 최적화하는 과정에서 군집화하는 방법이다.

분할 방법에서 대표적인 것으로는, 수렴상태가 될 때까지 평균(Centroid)에서 먼, 이미 군집화된 데이터를 추출하고 새로운 데이터를 군집에 유입하는 과정을 반복하는 k-평균(k-means) 알고리즘이 있다.

기업도산예측에 있어 통계적 군집방법을 활용한 연구로는 김경섭과 한인구의 연구가 있다. 여기서는 k-평균 알고리즘으로 감독(Supervised) 모형인 백프로파게이션(Back-propagation) 모형의 입력 자료를 군집화 전처리하여 예측률이 향상되었다(Kim and Han, 1996).

인공신경망 분야에서 패턴의 군집화를 수행하는 알고리즘으로 자기조직화지도 신경망이 있다. 자기조직화지도 신경망은 입력층과 경쟁층(Competitive Layer)이라고 불리우는 출력층으로 완전히 연결되어 (Fully Connected)있고, 출력층은 2차원 직방형 격자층으로 되어 있다. 아래의 그림 1은 자기조직화지도 신경망의 구조를 보여 주고 있다.

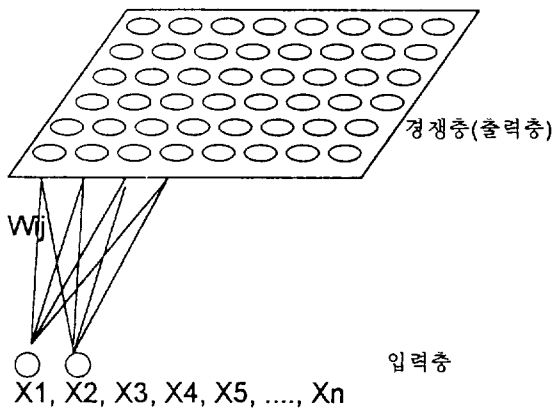


그림 1. 자기조직화지도 신경망의 구조

자기조직화지도 신경망은 다차원(Multi-variate) 자료를 학습하여 2차원 형태의 출력층에 투영시키며, 출력층에서는 투영된 입력자료가 유사한 패턴끼리 서로 모이도록 클러스터를 이루어 출력되게 된다. 자기조직화지도 신경망 알고리즘의 특징은 학습 시, 입력층과 출력층에 연결하는 모든 연결강도(W_{ij})를 조정하는 것이 아니라, 승자 노드와 이를 중심으로 이웃노드만이 학습된다는 것이다. 다음의 그림 2는 최신의 자기조직화지도 신경망 알고리즘이다.

자기조직화지도 신경망과 k-평균 알고리즘과의 군집 능력에 대한 비교연구로는 발라크리쉬난 등의 시장 세분화(Market Segmentation)에 대한 연구가 있었는데, 자기조직화지도 신경망이 k-평균 알고리즘보다 탁월한 성과를 보인 것으로 보고하였다 (Balakrishnan, et al., 1992; Balakrishnan, et al., 1996).

Consider iteration number t , lattice element i , dimension of input data N

Step 0 : Randomly initialize $W_i = (w_{i1}, w_{i2}, \dots, w_{iN})$ for each Kohonen PE i

Set $t=0$

Step 1 : Take an input data $X=(x_1, x_2, \dots, x_N)$ randomly from the set of input vectors.

Step 2 : Compute $D_i = ||X_j - W_i^{(t)}||$ for $1 < j < M$

Step 3 : Find the winner $c=i$ such that $D_i(t)$ is minimum for over all i

Step 4 : Update the winner c and its neighbors

$$W_i^{(t+1)} = W_i^{(t)} + \alpha^{(t)}(X_j - W_i^{(t)}) \text{ if } i \in N_c^{(t)}$$

$$W_i^{(t)} \text{ if } i \notin N_c^{(t)}$$

where $\alpha^{(t)}$ is a small linearly decreasing function

$N_c^{(t)}$ is the neighborhood of lattice element c , with decreasing radius

Step 5 : Increase t , Return Step 1, unless a stopping condition is reached.

그림 2. 자기조직화지도 신경망의 알고리즘

자기조직화 지도를 이용한 도산 예측에 대한 연구에서 이근창 등이 도산예측을 위해 백프로파게이션모형 투입 전에, 입력 데이터에서 규칙성을 탐색하기 위해 군집화 전처리 단계로 자기조직화지도 신경망과 학습 벡터 양자화(Learning Vector Quantization) 신경망을 사용하여 예측률을 향상시켰다(Lee et al., 1996).

기타 재무 영역의 연구에서 코트렐과 드볼트가 리스 의사결정시 자기조직화지도 신경망을 이용하여 비선형 차원 감소 방법으로 사용

했으며(Cottrell and de Bolt, 1996), 빙크스와 알리슨은 주가 방향성 예측 시 주가 방향성 패턴인식방법으로 자기조직화지도 신경망을 사용했다(Binks and Allison, 1991).

비재무 영역에서는 발라크리쉬난 등이 브랜드 선택 시 군집화 도구로(Balakrishnan et al., 1992), 키앙 등이 집단기술과 시장 세분화와 고객 선호 결정시 군집화 도구로(Kiang et al., 1995; Kiang et al., 1996) 사용했다. 또한, 카스키와 코호넨은 세계 부국 빈국간의 구조발견을 위한 군집화 도구로 자기조직화지도 신경망을 사용했다(Kaski and Kohonen, 1996).

4. 자기조직화지도 신경망을 이용한 변수 선택

도산예측 모형의 변수 선택에서는 기존 예측모형 들은 상관계수분석, 단계적 방법, 요인분석에 의한 방법 등 주로 통계적 방법을 채용했다. 반면, 인공지능기법에 의한 변수선택 방법으로는 유전자 알고리즘과 군집화방법인 자기조직화지도 신경망 방법이 있다.

본 절에서는 통계적 방법과 자기조직화지도 신경망 방법에 의해 각각 도산예측 변수를 선택한 후, 각각 선택변수들을 입력노드로 한 백프로파게이션모형으로 도산을 예측해 본다.

사용데이터는 국내 중기업 2056개(도산 1028개, 비도산 : 1028개)기업의 재무자료로, 훈련용 데이터(Training Data) 1486개, 검증용 데이터(Validation Data) 570개로 나뉘었다.

통계적 방법에 의한 경우, 상관계수분석, 단계적 방법으로 67개의 재무변수에서 14개의 변수를 선택하였는데 이 비율들은 그림 1과 같다.

한편, 자기조직화지도 신경망 방법의 경우에는 평균 양자화 오류(Average Quantization Error)가 0.73 이상인 재무변수를 선택하였는

데(전체변수의 평균 양자 오류는 0.51), 선택된 변수는 총 16개이며 해당 비율들은 표 1과 같다.

방법	변수리스트	
통계적 방법 (14)	안정성	업력
		자기자본비율
		고정장기적합율
		차입금의존도
	성장성	유동부채 대 총자본
		자기자본증가율
수익성	총자본경상이익율	
	적립금비율	
	경상수지비율	
	순금융비용 대 매출액	
활동성	매출채권회전율	
현금 흐름	영업활동후현금흐름 대 부채	
	이자지급후현금흐름 대 부채	
		외부자금조달전현금흐름대 부채
자기 조직화 지도 방법 (16)	안정성	업력
		재고자산 대 순운전자본비율
		유동부채 대 총자본
	수익성	총자본경상이익율
		매출원가율
		금융비용 대 부채비율
		경상수지비율
	활동성	순운전자본회전율
영업자본회전율		
매출채권회전율		
현금 흐름	부채상환계수	
	영업활동후현금흐름 대 부채	
		외부자금조달전현금흐름 대부채
규모	매출액	
	자기자본	
	순금융비용	

표 1. 각 방법에 의한 선택 변수 리스트

자기조직화지도 신경망에 의한 변수선택 방법에서는 각 유형의 비율이 비교적 고루 선택되었는데, 이는 직접적인 인과관계에 의한 설명력보다는 변별력을 중심으로 변수 선택이 이루어지므로 통계적 유의도 기준에 의한 일부 유형비율 들의 과다한 선택(Redundancy)을 방지하는 결과를 보였다.

즉, 평균 양자화 오류가 크다는 것은 데이터가 군집지도에 투영될 때, 지도상의 각 군집과의 뚜렷한 차이점(Dissimilarity)을 갖고 있음을 의미하며, 변수 선택 문제에서는 입력 데이터의 특정 변수값이 기타의 변수값과 상이하므로 예측모형에 입력변수로 이용할 때 차별력 있는(Distinct) 설명변수가 될 수 있다.

예측모형에의 투입을 위해 각 데이터들을 표준화(Standardization)시켰으며, 각 실험은 입력변수 종류, 입력노드 수 및 중간(Hidden) 노드 수에서만 차이가 있을 뿐(14-28-1 대 16-32-1), 나머지 조건은 동일한 상태에서 실험이 진행되었다. 각각의 예측결과는 다음 표 2에 나타냈는데, 여기서 모형 1(BPN_1)은 통계적 변수 선택방법에 의한 실험 결과이며 모형 2(BPN_2)는 자기조직화지도 방법에 의한 변수선택방법의 실험 결과이다.

검증용 데이터에 의하면, 전체 적중율은 1.6% 정도 향상되었지만, 여신기관에서 가장 중요한 부분인 제 2형 위험(Type II Error)이 5%가량 낮아지는 좋은 결과를 보였다.

5. 자기조직화지도에서의 시변량관계를 이용한 도산 징후 파악

자기조직화지도 신경망이 만든 군집화 지도에 검증용(Validation) 데이터를 투영하면 해당 데이터가 특정 군집 패턴으로 이동하여 군집화되게 된다. 본 절에서는, 이와 같은 원리를 활용하여 특정기업의 시변량 데이터를 입력하여 군집 지도에서 이동 상태를 파악할

BPN_1	훈련용데이터 (76.8%)		검증용 데이터 (77.0%)	
실제 \ 예측	도산	비도산	도산	비도산
도산	538/743 72.4%	205/743 27.6%	210/285 73.7%	75/285 26.3%
비도산	140/743 18.8%	603/743 81.2%	56/285 19.6%	229/285 80.4%

BPN_2	훈련용데이터 (77.3%)		검증용 데이터 (78.6%)	
실제 \ 예측	도산	비도산	도산	비도산
도산	544/743 73.2%	199/743 26.8%	224/285 78.6%	61/285 21.4%
비도산	156/743 21.0%	604/743 79.0%	61/285 21.4%	224/285 78.6%

표 2. 각 변수선택방법별 예측 성과표

수 있고 그 이동 궤적으로 도산징후 여부를 파악하는 것이 가능하다.

본 절의 연구에서는 국내 건설업체 60개의 총 168개의 재무데이터를 1991년부터 1995년까지 이용하였다.

건설업체 전체의 재무상태에 대한 자기조직화지도를 만들기 위해 변수를 선택하였다.

규모	자기자본
	매출액
	총부채
안정성	업력
수익성	경상자본영업이익률
	영업손실 지속연수
레버리지	자기자본비율
	단기부채/장기부채
현금흐름	2년 전 현금흐름
활동성	매입채무회전율

표 3. 선택변수

변수선택에서는 총 168개의 재무데이터에서 신용평가 전문가의 선택으로 67개로 감소시켰으며 단계적 방법, 크루스칼-왈리스(Kruskal-Wallice) 검정, 일원 분산분석 등의 통계적 방법에 의해 10개로 감소시켰다.

최종 선택 변수들은 앞쪽의 표 3과 같다. 이들 데이터는 자기조직화지도 신경망에 입력하기 위해 정규화시켰으며 아래의 표 4와 같은 파라미터로 훈련시켰다.

단계	1995		1991-95	
	order -ing	tuning	order -ing	tuning
학습회수	1,000	50,000	1,000	50,000
최소학습율	0.05	0.02	0.05	0.02
최소 훈련반경	8	2	8	2
평균양자오류	0.355655		0.902112	

표 4. 자기조직화지도 신경망 파라미터

실험결과 생성된 각 재무비율에 대한 특성지도(Feature Map)는 부록에 예시되어 있고, 이들 특성지도를 종합하면 다음의 그림 3과 같이 자기조직화지도 군집지도상의 군집영역을 정의할 수 있다.




그림 3. 군집지도

여기서 각 군집의 특성을 부록의 특성지도

에 의하여 정의해 보면 표 5와 같다.

군집	형태	특성
A	건전업체	큰 규모, 높은 안정성과 활동성
B1	건전업체	안정된 레버리지, 현금흐름 양호, 수익성 양호
B2	건전업체	B1과 유사, 경상자본수익율과 회전율 낮음
C	중간	현금흐름양호, 활동성 부족
D	중간	수익성양호, 단기부채 과다
E	중간	자기자본 양호, 수익성 낮음
F	중간	활동성, 자기자본 양호, 낮은 수익성
G	중간	활동성, 자기자본 불량, 단기채무 과다
H1	도산직전	자기자본 부족, 영업손실 지속, 낮은 수익성
H2	도산직전	H1과 유사, 현금흐름 불량

표 5. 각 군집의 특성

시변량분석(91-95)을 위해 검증용 표본으로 비도산 및 도산기업 각 3개사씩 6개 기업에 대한 시변량자료(91-95)를 앞의 군집지도에 투영해보면 아래와 그림 4와 같은 시변량지도를 얻는다.




그림 4. 시변량 지도

범례를 설명하자면, 앞의 숫자는 기업 코드로 뒤의 숫자는 해당 기업의 각 년도의 재무상태에 의거한 위치를 나타낸다.

먼저, 비도산 기업의 경우, 2번 기업은 경제지역에서 A 군집으로 이동하였는데, 이는 수익성이 개선된 결과로 설명된다. 3번 기업은 91년에는 도산 가능성을 보였는데(H2 군집 부근) A 군집으로 이동하였다. 이는 현금흐름과 활동성이 각각 개선되었기 때문이다.

도산기업의 경우, 37번 기업은 97년 부도처리되었다. 이 기업은 처음에는 B1 군집의 건실한 업체였는데, 현금흐름 부족, 부채증가, 영업손실 등의 이유로 H2 군집으로 이동하였다. 49번 기업은 96년 부도기업으로, 역시 수익성 악화, 자기자본 감소, 단기부채증가 등으로 B1 에서 E, H1 군집으로 이동하였다. 59번 기업 역시 96년 부도기업으로, B1 에서 D, H1 군집으로 이동하였는데, 주된 이유로는 매출감소, 영업손실 지속, 단기부채 증가를 들 수 있다.

6. 결론

본 논문에서는 자기조직화지도 신경망의 두 가지 활용예를 도산예측 문제를 중심으로 살펴 보았다.

변수 선택에서의 활용 예는 도산예측모형의 전처리 과정으로 활용한 경우로서, 기존의 통계적 변수 선택방법에 대해 하나의 대안적 방법으로 고려될 수 있다는 것을 발견하였다. 이 접근법의 수리적인 설명 및 타당성 검증부분이 향후 연구과제로 제시한다.


또한, 시변량 관계를 이용한 도산 징후 파악 활용 예는 여신 의사 결정자의 의사결정 지원시스템으로 발전이 가능하다. 물론, 본 논문에서는 군집지도상의 영역설정, 시변량관계 해석 등 인간 전문가의 개입이 일부 필요했으나, 활용의 실익이 많고 향후에는 자동화,

시스템화가 용이할 것으로 기대된다.


본 연구에서 제기된 두 가지 활용 예는 데이터 마이닝의 범주에서 의미가 있다. 즉, 날로 커지는 재무 데이터베이스에서 비록 사전적으로는 알지 못했지만, 타당성이 있고 의사결정에 유용한, 해석 가능한 정보를 자동적으로 발견, 추출하는 과정의 활용 예의 일부로 제시되었기 때문이다.

부 록 특성 지도


규모 : 자본(검은색:낮음, 흰색:높음)




규모 : 매출액




규모 : 총부채




안정성 : 영업 년수




수익성 : 경상자본수익률




수익성 : 영업손실 지속연수




레버리지 : 자기자본비율




레버리지 : 단기부채/장기부채



현금흐름 : 2년전 현금흐름



활동성 : 매입채무회전율



참고문헌

1. 김상운(1995), 패턴인식 입문, 홍릉과학출판사.
2. Balakrishnan, P.V., M. Cooper, V.S. Jacob and P.A. Lewis (1992). A cluster analysis of brand choice data using neural networks. *Working paper*, WP92-6-001, The Ohio State University.
3. Balakrishnan, P.V., M. Cooper, V.S. Jacob and P.A. Lewis (1992). A study of the classification capabilities of neural networks for market segmentation : A comparison with k-means clustering. *Working paper*, WP92-7-002, The Ohio State University.
4. Balakrishnan, P.V., M. Cooper, V.S. Jacob and P.A. Lewis (1996). Comparative performance of the FSCL neural net and k-means algorithm for market segmentation. *European Journal of Operational Research*, 93, 346-357.
5. Berry, R. and D. Trigueiros (1993). Applying neural networks to the extraction of knowledge from accounting reports: A classification study. In R.R. Trippi and E. Turban (Eds.), *Neural Networks in Finance and Investing* (pp. 103-124). Chicago: Probus Publishing Company.
6. Binks, D.L. and N.M. Allison (1991). Financial data recognition and prediction using neural networks. In T. Kohonen et al. (Eds.) *A neural networks*, Vol.II, 1709-1712.
7. Chen, S.K., P. Mangiameli and D. West (1995). The comparative ability of self-organizing neural networks to define cluster structure. *Omega, International Journal of Management Science*, 23(3), 271-279.
8. Cottrell, M. and E. de Bolt (1996). Understanding the leasing decision with the help of a Kohonen map : An empirical study of the Belgian market, *Proceedings of IEEE International Conference on Neural Network*, 1996, 2027-2032.
9. Dillon, W.R. and M. Goldstein (1984). *Multivariate Analysis: Methods and Applications*, John Wiley and Sons.
10. Kaski, S. and T. Kohonen (1996). Exploratory data analysis by the self-organizing map: Structures of welfare and poverty in the world. In Refenes, A., Abu-Mostafa, Y., Moody, J. and A. Weigend, (Eds.) *Neural Networks in Financial Engineering*, Proceedings of the Third International Conference on NNCM, 1996, 498-507.
11. Kaski, S. (1997). Data Exploration using self-organizing maps. *Unpublished doctoral dissertation*, Neural networks Research Centre, Helsinki University of Technology, Helsinki.
12. Kiang M.Y., U.R. Kulkarni and K.Y. Tam (1995). Self-organizing map networks as an interactive clustering tool - An application to group technology. *Decision Support Systems*, 15 351-374.
13. Kiang M.Y., R.T. Chi and K.Y. Tam (1996). A decision support system for market segmentation- A neural networks approach. *Published in Internet*, <http://hsb.baylor.edu/ramsower/acis/papers/kiang.htm>.
14. Kim, K. and I. Han (1996). Combining cluster analysis and neural networks for the classification problem. *Proceedings of Conference of the Korean Operation Research and Management Science Society*, 1996(Fall), 31-34.
15. Kohonen, T.(1990). The self-organizing map. *Proceedings of the IEEE*, 78(9):1464-1480.
16. Kohonen, T., J. Hynninen, J. Kangas and J.

- Laaksonen (1996). SOM_PAK : The Self-Organizing Map Program Package. *Unpublished Materials*, Report A31, HIT
17. Lee, K.C., I. Han and Y. Kwon (1996). Hybrid neural network models for bankruptcy predictions. *Decision support systems* 18, 63-72.
 18. Mar Molinero C. and M. Ezzamel (1991). Multidimensional scaling applied to corporate failure. *Omega, International Journal of Management Science*, 19(4), 259-274.
 19. Martin-del-Brio, B. and C. Serrano-Cinca (1993). Self-organizing neural networks for the analysis and representation of data : some financial state cases. *Neural Computing and Applications*, 1(3), 193-206.
 20. Martin-del-Brio, B. and C. Serrano-Cinca (1995). Self-organizing neural networks: The financial state of Spanish Companies. In A. Refenes (Eds.), *Neural Networks in the Capital Markets*, 341-357., John Wiley and Sons.
 21. Moxon, B. (1996). Defining Data Mining., *DBMS Data Warehouse Supplement*, 1-6.
 22. Murtagh, F. and M. Hernandez-Pajares, The Kohonen self-organizing map method :An assessment, *Unpublished Materials*.
 23. Serrano-Cinca, C. (1996). Self organizing neural networks for financial diagnosis. *Decision Support Systems*, 17, 227-238.
 24. Vermeulen, E., J. Spronk and D. van der Wijst (1994). Visualizing interfirm comparison *Omega, International Journal of Management Science*, 22(4), 331-338.