

통합 연결강도모형에 의한 부도예측용 인공신경망 모형 입력노드 선정에 관한 연구

(Selection of Input Nodes in Artificial Neural Network for Bankruptcy Prediction by Integrated Link Weight Analysis)

이웅규

대구대학교 경영학과 (wklee@biho.taegu.ac.kr)

요약문

본 연구에서는 부도예측용 인공신경망의 입력노드 선정에 관한 휴리스틱으로 연결강도분석접근법을 제안한다. 연결강도분석은 학습이 끝난 인공신경망에서 입력노드와 은닉노드와 연결된 가중치의 절대값 즉, 연결강도를 분석하여 입력변수를 선정하는 접근법으로, 본 연구에서는 약체연결뉴론제거법, 강체연결뉴론선택법 그리고 이 두 기법을 통합한 통합 연결강도 모형을 제안하여 각각 의사결정트리 및 다변량판별분석에 의해 선정된 입력변수를 이용한 인공신경망 모형과 예측율을 비교한다. 실험 결과 본 연구에서 제안하고 있는 방법론이 의사결정트리나 다변량판별분석 기법 보다 높은 예측율을 보여 주었다. 특히 두 기법의 통합연결강도 모형의 경우에는 다른 단일 기법보다 높은 예측율을 보이고 있다.

1. 서론

이웅규 등이 제안한 연결강도분석은 부도예측용 인공신경망의 입력변수를 선정하는 휴리스틱으로서 학습이 끝난 인공신경망에서 입력노드와 은닉노드를 연결하는 연결가중치의 절대값 즉,

연결강도를 분석하여 입력변수를 선정한다(이웅규 외, 2000A; 2000B). 본 연구에서는 약체연결뉴론제거법과 강체연결뉴론선택법을 통합한 통합 연결강도모형을 제안하여 각각 의사결정트리 및 다변량판별분석에 의해 선정된 입력변수를 이용한 인공신경망 모형과 예측율을 비교하고자 한다.

본 논문의 구성은 다음과 같다. 2절에서는 부도예측을 위한 통계적 기법과 인공지능 기법을 살펴보고, 인공신경망 기법에서의 변수 선정에 관한 기법과 그 한계점을 논의한다. 3절에서는 본 연결강도분석 접근법의 개념과 방법을 소개하고 4절에서는 실험설계에 대해서 기술하고 5절에서는 본 연결강도분석에 의한 모형과 의사결정트리 및 다변량판별분석에 의한 모형 구축에 대해 기술하고 6절에서는 실험결과에 대한 분석을 하며 마지막으로 7절에서는 본 연구의 기여도 및 향후 연구과제에 대해 논의하도록 한다.

2. 문헌고찰

초기의 부도예측에 관한 연구는 다변량판별분석(Altman, 1968)이나 로짓회귀분석, 프로빗분석과(Ohlson, 1980 ; Zmijewski, 1984)과 같은 통계적 기법이 주로 이용되어 왔으나, 1980년대

후반부터 다층퍼셉트론(Multi-Layered Perceptrons) (이재규 외 1998; Berry and Linoff, 1997; Hertz et. al., 1991)에 의한 인공지능망의 가능성이 새롭게 인정되면서부터 다층퍼셉트론 인공지능망에 의한 부도예측 연구가 활발히 진행되었고, 실제로 통계적 기법보다 뛰어난 예측력을 보여주고 있음이 입증되고 있다 (조홍규, 1999; Zhang et. al., 1999; Lee, et al., 1996; Wilson, 1994; Tsukuda, 1994; Fletcher, 1993; Udo, 1993; Raghupath et. al., 1991; Salchengerger et. al., 1992; Tam and Kiang 1991; Odom and Sharda, 1990).

인공지능망에 의한 모형화과정에서 가장 중요한 고려사항 중의 하나는 적절한 입력노드의 선정인데, 그 이유는 지나치게 많은 입력노드는 많은 학습시간을 요구할 뿐 아니라 적절치 못한 해(Solution)를 도출할 가능성이 높기 때문이다. 따라서 적절한 입력노드의 선정을 위해 전문가의 직관이나 분석에서부터 통계적 분석, 의사결정트리 등 다양한 기법이 제안되고 있다 (Berry and Linoff, 1997).

그러나, 기존의 입력변수 선정기법은 나름대로의 한계점을 보유하고 있는데, 다변량 판별분석의 경우 독립변수들의 집단이 다변량 정규분포를 이루면서 공분산이 같아야 하는 가정이 필요하기 때문에 이에 대한 검증을 필요로 한다(채서일, 1999 ; Tam and Kiang, 1992). 의사결정트리의 경우 독립변수와 종속변수의 관계를 쉽게 설명할 수 있는 IF~THEN 규칙을 생성하는 장점이 있어서 결과를 쉽게 이해하고 설명하고자 할 때 적합한 방법이지만(Messier and Hansen,

1988), 독립변수가 취할 수 있는 값이 많아질 경우에는 오류가 발생할 가능성이 많다는 약점을 가지고 있다(Berry and Linoff, 1997). 자기조직화 형상지도에 의한 변수 선정방법은 자율학습(Unsupervised Learning) 을 채택하고 있기 때문에 자칫 부도예측과 상관이 없는 변수 분류를 초래할 가능성이 있다 (이재규 외 1998; Berry and Linoff, 1997; Hertz et. al., 1991).

한편 최근 유전자알고리즘과 인공지능망의 결합에 의한 연구가 활발한데 부도예측에서도 유전자알고리즘에 의한 입력변수 선정을 시도하여 기존의 통계적 기법보다 더 좋은 예측율을 보이고 있다(Shin and Hong, 2000).

3. 연결강도분석 접근법

연결강도분석은 다층퍼셉트론 구조를 갖는 인공신경망에서 학습이 끝난 연결가중치의 값에 따라 입력변수를 선정하는 접근법으로 약체연결뉴론제거법과 강제연결뉴론선택법으로 나눌 수 있다 (손동우 외 2000; 이용규 외, 2000B).

3.1 약체연결뉴론제거법

약체연결뉴론제거법은 크게 제거대상변수 선정과 약체연결뉴론제거모형 선정으로 나뉜다.

제거대상변수 선정은 인공지능망모형을 학습시킨 후 연결강도가 일정한 값 즉, 연결강도 임계치보다 낮은 입력노드를 제외한 나머지를 가지고 새롭게 학습을 한다. 이 때 제외된 변수는 제거대상변수 목록에 저장을 하고 이와 같은 과정을 다음과 같은 세 가지 가운데 한 가지가 나올 때까지 계속 반복한다.

첫째, 연결강도 값이 연결강도 임계치보다 작은 입력노드가 나오지 않는다.

둘째, 인공신경망의 성능이 더 이상 개선되지 않는다.

셋째, 반복횟수가 일정 횟수에 도달했다.

인공신경망 학습결과의 무작위성을 반영하기 위해 위의 과정을 일정 라운드 수만큼 반복하여 제거대상변수 목록을 완성한다 (이용규 외 2000A; 2000B).

제거대상변수 목록이 작성되면 제거대상변수의 빈도수를 기반으로 하여 약체연결뉴론제거 모형인 WL(x)들을 구성한다. 즉, x개 이상 나온 변수들을 제외한 변수만으로 만들어진 신경망모형을 말한다. 가령 WL(8)인 경우 8번 이상 제거대상변수로 나온 변수를 일컫는 것이다.

3.3 강제연결뉴론선택법

강체연결뉴론선택법의 경우에도 약체연결뉴론제거법에서와 유사하게 선택대상변수 선정과 강제연결뉴론선택모형 선정의 두 단계로 나뉘어 진다.

약체연결뉴론제거법에서와 같이 대상이 되는 변수의 수 만큼의 입력노드와 하나의 은닉노드로 이루어진 인공신경망 모형을 이용하는데 연결강도가 낮은 뉴론을 제거하는 대신에 연결강도가 높은 뉴론을 선정하는 방식으로 전개된다. 약체연결뉴론제거법과 마찬가지로 인공신경망모형을 학습시킨 후 연결강도가 가장 높은 값을 선정하여 이를 제외한 나머지를 가지고 새롭게 학습을 한다. 이때 인공신경망의 성능이 더 이상 개선되지 않거나 반복횟수가 일정횟수에 도달할 때까지 학습을 반복하여 여기서 선정된 변수들은 선택대상변수 목록에 포함한다. 약체연결뉴론제거법에서와 마찬가지로 이와

같은 라운드를 일정 횟수만큼 반복한다(이용규 외 2000A; 2000B).

역시 약체연결뉴론제거법에서와 유사하게 x번 이상 선택대상변수 목록에 들어간 변수만으로 입력노드를 구성한 강제연결뉴론선택 모형 SL(x)을 구성한다.

3.4 통합 연결강도 모형

두 가지 방법론에 의해 생성된 모형들을 각각 학습시켜 최적 모형으로 만든 다음 각 모형들의 출력값에 대한 평균값을 구하는 Bagging 방식에 의한 Ensemble 기법(Heskes, 1996)으로 약체연결뉴론제거 통합모형과 강제연결뉴론선택 통합모형을 구성하고, 두 모형의 평균값에 구하여 통합 연결강도 모형을 구성한다.

4. 실험설계

4.1 비교대상 모형

본 연구에서는 위에서 제시한 약체연결뉴론제거 통합모형과 강제연결뉴론선택 통합모형 그리고 전체를 통합한 통합연결강도 모형 등 세가지의 접근모형을 C4.5 알고리즘에 의한 의사결정트리 (Quinlan, 1992)와 다변량판별분석의 설명변수 선택방식인 단계별 선택법(Stepwise Selection) (채서일 1999)에 의해 각각 입력노드를 선정한 인공신경망모형과 비교하도록 한다.

한편 본 연구에서 사용된 소프트웨어는 인공신경망과 의사결정트리의 경우 엔터프라이즈 마이너(Enterprise Miner) 3.0이 이용되었고 다변량판별분석의 경우 SAS 6.12가 이용되었다.

4.2 사용 변수

일반적으로 인공지능망에 의한 부도예측에는 Altman(1968)이 제안한 다섯 가지의 재무비율(순운전자본구성비율, 이익잉여금구성비율, 총자산영업이익율, 장부가치, 총자산회전율)을 사용하고 있지만 Raghupathi 등(1998)은 13개의 재무비율 변수를 Salchengerer 등(1992)은 29개의 변수 그리고 Tam과 Kiang(1992)은 19개의 변수를 사용하고 있다. 한편 Shin과 Hong(2000)은 재무비율 이외에 현금흐름지표를 변수에 포함하고 있다. 본 연구에서는 다음과 43개의 재무비율과 현금흐름지표를(부록-1 참조) 대상으로 하여 적절한 입력변수를 선정한다.

4.3 샘플링 방법

전체 475개의 국내 기업 (부도기업 238개, 건전기업 237개)을 대상으로 하였는데 이 가운데 무작위로 추출한 100개(부도기업 56개, 건전기업 44개)는 스코어링을 위해 사용하였고 나머지 375개를 변수 선정과 학습(Training) 및 검증(Validation)을 위해 사용하였다.

스코어링을 위해 선정된 100개를 제외한 나머지 375개 가운데서 다시 100개 기업(건전기업 50개, 부도기업 50개)을 무작위로 추출하여 제거대상변수 목록 및 선정대상 변수 목록을 만드는데 사용하였다.

또 약체연결뉴론제거 모형(WL*)과 강체연결뉴론선택 모형(SL*)를 구하기 위해 375개의 데이터를 다시 학습용 150개 검증용 150개 그리고 테스트용 75개를 10회에 걸쳐 무작위 추출하는 방식으로 모형을 구축하였고 다변량판별분석과 의사결정트리에 의한 모형의 경우에도 375개의 데이터를 이용하여 모형을

구축하였다.

최종적으로 100개의 스코어링용 데이터를 이용하여 각 모형의 성능을 비교분석하였다.

5. 모형의 구축

5.1. 약체연결뉴론제거 모형

총 라운드 수 (R)은 10회로 하였고 라운드별 제한횟수(K)도 10회로 제한하였으며 연결강도임계치(α)는 0.05로 하여 실험을 하여 [표-1]와 같은 제거대상변수 목록을 작성하였다.

[표-1] 제거대상변수 목록

빈도수	제거대상변수
10	X60
9	X32, X36, X47, X70
8	X25, X31, X59, X62, X69
7	X15, X23, X27, X33, X35, X39, X52, X53, X61, X68
6	X10, X13, X19, X21, X28, X34, X41, X55, X56, X64
5	X9, X18, X37, X43, X50, X73
4	X14, X29, X44, X46
2	X38
1	X42, X49

제거대상변수 목록에 10회, 9회, 8회, 7회, 6회, 5회, 4회, 2회, 1회에 걸쳐서 제거대상변수로 나타난 변수를 각각 누적하여 제거한 후 나머지 변수를 입력변수로 약체연결뉴론제거모형인 각각의 WL(x) 모형을 얻었다. 즉, WL(x)는 x회 이상 제거대상변수로 선정된 변수를 제외한 변수들을 입력노드로 하여 구축된 모형이다. WL(x) 모형들의 은닉노드의 수는 각 입력노드의 수와 같도록 구조를 설정하여 10회에 걸쳐 실험을 하였다. 이 때 앞에서 언급한 바와 같이 375개의 데이터를 10회에 걸친 무작위 추출을 통해 학습용, 검증용 및 테스트용으로 구분하여 각

경우의 최적모형을 구하였다.

5.2 강제연결뉴론선택 모형

최적 약체연결뉴론제거모형과 유사하게 라운드 수 (R)은 10회로 라운드별 제한횟수 (K)도 10회로 하여 진행하여. [표-2]와 같은 선택대상변수 목록을 얻었다.

[표-2] 선택대상변수 목록

[표-2]에서 보는 바와 같이 10회에

빈도 수	변수
0	X15, X21, X23, X25, X27, X28, X31, X34, X53, X59
1	X9, X10, X29, X36, X42, X43, X52, X60, X61, X67, X70, X73
2	X32, X33, X35, X38, X39, X62, X69
3	X14, X37, X66
4	X18, X41, X44, X47, X56
5	X50
6	X13
7	X46, X55
10	X19, X49

걸쳐서 선택대상변수로 선정된 변수는 X19, X49 두 개의 변수이고, 9회와 8회 선정된 변수는 없었으며, 7회 선택대상변수로 선정된 것은 X46, X55이며 6회 선정된 변수는 X13이다. 이를 기반으로 x회 이상 선택대상변수 목록에 포함된 변수만으로 입력노드를 선정한 SL(x) 즉, 강제연결뉴론선택모형을 구성하여 WL(x)의 경우와 마찬가지로 입력노드 수와 은닉노드 수를 같게 하여 10회에 걸쳐 실험을 하였다.

형명(예측율)	WL*(83%)	SL*(82%)	WL** SL*(86%)
DA(68%)	1.630482*	1.514112*	1.99073*
REE(79%)	0.900131	0.783362	1.260871**

역시 WL(x)의 경우에서와 마찬가지로 375개의 데이터를 10회에 무작위 추출을

하여 각기 샘플의 구성을 달리하여 실험하여 각 경우의 최적모형을 구하였다.

5.3 통합모형의 구성

각 모형 가운데서 지나치게 예측율이 낮은 모형을 제외하고 통합한 결과 약체연결뉴론제거 통합모형은 W(6), W(7), W(8), W(9) 그리고 강제연결뉴론선택 통합모형의 경우는 S(5), S(6), S(7), S(10)을 이용하여 통합모형을 구성하여

5.3. 의사결정트리 및 다변량판별분석에 의한 모형

부록-2와 부록-3에서 보는 바와 같이 의사결정트리의 경우 X43, X29, X62, X14 등 4개의 변수가 선정되었고, 다변량판별분석의 경우 X13, X15 등 16개의 변수가 선정되었다.

6. 실험결과 분석

각 모형의 예측율을 얻기 위해 이제까지 훈련이나 검증에 전혀 사용되지 않은 데이터 100개를 스코어링용으로 사용하였다. 각 모형별 예측율 및 쌍체검증 결과는 [표-3]과 같다. 약체연결뉴론 통합모형(WL*)의 경우 83%, 강제연결뉴론선택모형(SL*)의 경우는 82% 그리고 통합연결모형의 경우 86%의 예측율을 보임으로써 세 통합모형이 모두 다변량판별분석의 68% 보다 통계적으로 유의적 차이를 보여 주고 있다. 반면 의사결정트리(79%)과는 연결통합모형만이 통계적으로 유의적 차이를 보여 주고 있다.

[표-3] 모형별 예측율 및 모형간의

쌍체검증(z-검증) 결과

*: 통계적 유의수준 5%

** : 통계적 유의수준 10%

7. 결론

본 연구에서는 약체뉴론제거법과 강제뉴론선택법의 통합모형을 제시하여 의사결정트리나 다변량관별분석보다 높은 예측율을 보이고 있음을 보여 주었다. 비록 의사결정트리에 의한 변수 선정과는 통계적으로 유의한 차이를 보여 주지 못하고 있으나 다변량관별분석에 의한 변수 선정과는 유의한 차이를 보여 주고 있다.

본 연구의 향후 과제로는 다음과 같은 세 가지를 들 수 있다.

첫째, 가중평균법에 의한 모형의 통합이다. 본 연구에서의 통합은 각 모형의 출력값에 대한 단순 평균한 것을 기반으로 하고 있으나 향후에는 모형별 중요도에 따른 가중 평균이 필요하다. 이를 위해서 유전자 알고리즘에 의한 학습을 고려해 볼 수 있다.

둘째, 본 연구의 한계와도 연관되는 문제인데 좀 더 최적화된 인공신경망 모형을 통해 좀 더 나은 타당성을 얻어 보는 것도 좋은 연구과제가 될 것으로 보인다. 본 연구에서는 대부분의 경우 입력노드와 은닉노드의 수를 같도록 모형의 구조를 만들었고, 또 연결강도 분석에서는 은닉노드의 수를 하나로 고정하였다. 이러한 방식은 사실 여러 번의 실험에 걸친 결과이긴 하지만 완전한 최적성을 보장할 수 없음을 인정한다.

세 번째로는 보다 방대한 데이터와 다양한 데이터로 실험하여 본 연구의 결과를 좀 더 일반화해 볼 필요성도 있다. 본 연구에서 사용한 데이터셋의 규모를 좀 더 확장시킨다던지, 혹은 우리나라가 아닌 다른 나라에의 데이터를 적용할 경우 좋은 결과를 얻을 수 있을 것으로 보인다.

참고문헌

- [1] 박정식, 신동령, '경영분석', 다산출판사 1999.
- [2] 손동우, 이용규, "약체연결뉴론 제거법에 의한 부도예측용 인공신경망 모형에 관한 연구", 2000년도 춘계학술대회 발표논문집, 한국정보시스템학회, 2000.
- [3] 이용규, 손동우, "부도예측용 인공신경망모형의 최적 입력노드 설계: 연결강도관별분석 접근", 2000 춘계정기학술대회, 한국지능정보시스템학회, 2000(A)
- [4] 이용규, 손동우, "연결강도관별분석에 의한 부도예측용 신경망 모형의 입력노드 설계 : 강제연결뉴론 선정 및 약체연결뉴론 제거 접근법", 2000 추계정치학술대회, 한국지능정보시스템학회, 2000(B).
- [5] 이재규, 최형림, 김현수, 서민수, 추석진, 지원철, '전문가시스템 원리와 개발', 법영사, 1998.
- [6] 조홍규, "도산예측을 위한 인공지능 방법과 통계적 방법의 통합 방법론," 한국과학기술원(박사학위논문) 1999.
- [7] 채서일, '사회과학 조사방법론', 학현사, 1999. , 2판.
- [8] Altman, Edward I., "Financial Ratios, Discriminant Analysis and Prediction of Corporate Bankruptcy", Journal of Finance, Sep.1968, pp.589-609.
- [9] Altman, Edward I., "Accounting Implications of Failure Prediction Models", Journal of Accounting, Auditing and Finance 18, 1982, pp505-

- 529.
- [10] Berry, Michael J. A. and Gordon Linoff, 'Data Mining Techniques: For Marketing, Sales, and Customer Support', John Wiley and Sons, 1997.
- [11] Dahr, Vasant and Roger Stein, 'Intelligent Decision Support Methods: The Science of Knowledge Work', Prentice Hall, Upper Saddle River, NJ, 1997.
- [12] Fletcher, D. and E. Goss, "Forecasting with Neural Networks: an Application using Bankruptcy Data", *Information and Management*, 24. 3, 1993, pp.159-167
- [13] Hertz, John, Anders Krogh and Richard G. Palmer, 'Introduction to the Theory of Neural Computation', Addison Wesley, 1991.
- [14] Heskes, T., "Balancing between Bagging and Bumpling", In Mozer, M. C., M. I. Jordan, and T. Petsche, (eds.) *Advances in Neural Information Processing Systems 9*, The MIT Press, 1996.
- [15] Lee, Kun Chang, Ingo Han and Youngsig Kwon, "Hybrid Neural Network Models for Bankruptcy Predictions", *Decision Support Systems*, 18, 1996, pp.63-72.
- [16] Messier, William F. Jr. and James V. Hansen, "Inducing Rules For Expert System Development: An Example Using Default and Bankruptcy Data", *Management Science*, Vol.34, No.12, December, 1988, pp.1403-1415.
- [17] Odom, M., R. Sharda, "A Neural network Model for Bankruptcy Prediction", In *Proceedings of the IEEE International Conference on Neural Network*, 1990, pp 163-168.
- [18] Ohlson, J. "Financial Ratios and The Probabilistic Prediction of Bankruptcy", *Journal of Accounting Research*, 18. 1, 1980, pp.109-131.
- [19] Opitz D. W., and J. W. Shavlik, "Generating Accurate and Diverse Members of Neural-Network Ensemble", In Mozer, M. C., M. I. Jordan, and T. Petsche, (eds.) *Advances in Neural Information Processing Systems 9*, The MIT Press, 1996.
- [20] Quinlan, J.R., *C4.5: Programs for Machine Learning*, Morgan Kaufman, Mountain View, CA, 1992.
- [21] Raghupathi, W., L. L. Schkade, and B. S. Raju, "A Neural Network Approach to Bankruptcy Prediction", In *Proceedings of the 24th Hawaii International Conference on System Science*, 1991, pp 147-155.
- [22] Salchengerger, L. M., E. M. Cinar and N. A. Lash, "Neural Networks: A New Tool for Predicting Thrift Failures", *Decision Sciences Vol 24*, No 4, 1992, pp899-916.
- [23] Serrano-Cinca, Carlos, "Self Organizing Neural Networks for Financial Diagnosis", *Decision Support Systems*, 17, 1996, pp.227-238.
- [24] Shin, Kyung-shik and Seung-hyun

- Hong, "A GA-based Input Selection Approach for Neural Networks Modeling: Application to Bankruptcy Prediction", Proceedings of the 5th Asia-Pacific Decision Sciences Institute Conference, Tokyo, Japan, 2000.
- [25] Sung, Tae Kyoung., Namsik Chang and Gunhee Lee, "Dynamics of Modeling in Data Mining: Interpretive Approach to Bankruptcy Prediction," Journal of Management Information Systems, Vol.16, No.1, Summer.1999, pp.63-85.
- [26] Tam, Kar Yan And Melody Y Kiang., "Managerial Applications of Neural Networks: The Case of Bank Failure Predictions", Management Science, Vol.38, No.7, July.1992, pp.926-947.
- [27] Tsukuda, J., and S. L. Baba, "Predicting Japanese Corporate Bankruptcy in terms of Financial Data Using Neural Network", Computers and Industrial Engineering, 27(1-4), 1994, pp.445-448
- [28] Udo, G., "Neural Network Performance on the Bankruptcy Classification Problem", Computers and Industrial Engineering, 25(1-4).1993, pp.377-380.
- [29] Wilson, Rick L. and Ramesh Sharda,"Bankruptcy Prediction using Neural Networks", Decision Support Systems, 11. 1994., pp. 545-557.
- [30] Zhang, Guoqiang, Michael Y. Hu, B. Eddy Patuwo, and Daniel C. Indro, "Artificial Neural Networks in Bankruptcy Prediction: General Framework and Cross-Validation Analyiss", European Journal of Operational Research, Vol 116, 1999, pp16-32,
- [31] Zmijewski, Mafke, "Methodological Issues Related to the Estimation of Financial Distress Prediction Models", Journal of Accounting Research, Vol.22 1984,

부록-1 전체변수 내역

번호	지표	변수	변수내역
1	규모(1)	x9	매출액
2	규모(1)	x10	자기자본
3	생산성(2)	x13	총자본투자효율
4	생산성(2)	x14	부가가치율
5	성장성(3)	x15	매출액증가율
6	성장성(3)	x18	재고자산증가율
7	성장성(3)	x19	총자산증가율
8	수익성(4)	x21	금융비용대 매출액비율
9	수익성(4)	x23	대출효율성계수
10	수익성(4)	x25	매출액순이익률
11	수익성(4)	x27	매출원가율
12	수익성(4)	x28	손익분기점율
13	수익성(4)	x29	순금융비용대 매출액비율
14	수익성(4)	x31	이자보상배율
15	수익성(4)	x32	자기자본순이익률
16	수익성(4)	x33	총자본경상이익률
17	수익성(4)	x34	총자본순이익률
18	안정성(5)	x35	고정장기적합율의 역
19	안정성(5)	x36	단기부채대 총차입금
20	안정성(5)	x37	당좌비율
21	안정성(5)	x38	매출채권대 매입채무
22	안정성(5)	x39	순운전자본비율
23	안정성(5)	x41	유동비율
24	안정성(5)	x42	유동부채대 총자본
25	안정성(5)	x43	유보액대총자산비율
26	안정성(5)	x44	자기자본비율
27	안정성(5)	x46	차입금의존도
28	안정성(5)	x47	총차입금대 매출액
29	추세(6)	x49	금융비용부담금율 증가율
30	활동성(7)	x50	매입채무회전율
31	활동성(7)	x52	순운전자본대 매출액
32	활동성(7)	x53	운전자금대 회전율
33	활동성(7)	x55	재고자산회전율
34	활동성(7)	x56	총자본회전율
35	현금흐름지표(8)	x59	(영업활동후 CF/차입금합계)*100
37	현금흐름지표(8)	x61	영업활동후 CF/금융비용
38	현금흐름지표(8)	x62	(현금영업이익/금융수입)/금융비용
39	현금흐름지표(8)	x66	(이자지급후 CF/부채총계)*100

40	현금흐름지표(8)	x67	이자지급후 CF/금융비용
41	현금흐름지표(8)	x69	(외부자금조달전 CF/차입금합계)*100
42	현금흐름지표(8)	x70	외부자금조달전 CF/금융비용
43	현금흐름지표(8)	x73	외부자금조달후 CF/금융비용

부록-2 의사결정트리에 의해 선정된 변수

지표명	변수명	변수내역
안정성	X43	유액대총자산비율
수익성	X29	순금융비용대 매출액비율
현금흐름지표	X62	(현금영업이익/금융수입)/금융비용
생산성	X14	부가가치율

부록-3 다변량판별분석에 의해 선정된 변수

지표명	변수명	변수내역
생산성	X13	총자본투자효율
생산성	X14	부가가치율
성장성	X15	매출액증가율
성장성	X18	재고자산증가율
성장성	X19	총자산증가율
수익성	X27	매출원가율
수익성	X29	순금융비용대 매출액 비율
수익성	X32	자기자본순이익율
안정성	X35	고정장기적합율의 역
안정성	X37	당좌비율
안정성	X41	유동비율
안정성	X42	유동부채대 총자본
안정성	X44	자기자본비율
활동성	X52	순운전자본대 매출액
활동성	X53	운전자금대 회전을
규모	X9	매출액