

다수의 인공신경망 모형을 통합한 기업부도 예측모형에 관한 연구 Bankruptcy Prediction Modeling Using Multiple Neural Networks Models

신경식, 한인구

한국과학기술원 테크노경영대학원
서울시 동대문구 청량리동 207-43
E-mail: ksshin@kgsm.kaist.ac.kr

1. 서론

인공신경망(artificial neural networks)을 이용한 가장 중요한 연구 중의 하나는 축적된 자료를 이용하여 독립변수와 종속변수간의 결합관계를 추출해 냄으로써 패턴인식, 분류, 예측 등의 기능을 수행하는 모형을 구축하는 것이다. 많은 선행 연구들은 인공신경망 기법이 기존의 통계적 기법에 비해 그 예측력이 우수한 것으로 보고하고 있으며 (이건창 등, 1994; Barniv, Agarwal and Leach, 1997; Bell, 1997; Boritz and Kennedy, 1995; Chung and Tam, 1992; Etheridge and Sriram, 1997; Fletcher and Goss, 1993; Jo et al. 1997; Odom and Sharda, 1990; Salchenberger et al., 1992; Tam and Kiang, 1992; Wilson and Sharda, 1994), 부도예측, 채권평가, 주가, 금리, 환율 등의 재무예측 등 회계 및 재무분야에 다양하게 적용되고 있다.

부도예측분야에 있어서 인공신경망은 규칙기반 전문가시스템의 한계점인 지식의 획득 문제를 완화시켜 줄 수 있다는 장점 때문에 많이 적용되고 있다 (한인구와 신경식, 1998). 일반적인 부도예측모형은 부도 및 건전기업의 과거 재무 및 비재무정보를 입력변수로, 해당기업의 부실여부를 종속변수로 설정하여 모형을 구축하며, 이 과정을 통해 구축된 모형을 이용하여 현재 심사대상 기업들을 분류하게 된다.

최근의 연구들은 인공신경망과 기존 통계기법의 성과를 비교, 분석하는 연구에서 나아가 다양한 방법론을 통해 모형의 예측력을 향상시키기 위한 방안들을 제시하고 있다. 이에 관련된 연구로는 이재식과 한재홍(1995), 이재식과 차봉근(1996), 이건창 등(1996), 한인구 등(1997)의 연구가 있다.

이재식과 한재홍(1995)은 비재무정보를 입력변수에 반영함으로써 재무정보만을 이용한 모형에 비해 10% 정도 증가된 예측률을 보이고 있다. 이재식과 차봉근(1996)은 인공신경망 모형의 최적의 입력변수를 선정하기 위하여

유전자알고리즘을 사용하고 있다. 이건창 등 (1996)의 연구에서는 인공신경망과 다변량 판별분석 (MDA: multiple discriminant analysis), 귀납적 학습방법 (ID3), SOFM(self organizing feature map) 등의 기법과의 통합 방법론을 적용하였는데, 실증분석결과 향상된 예측성과를 보이고 있다.

한인구 등 (1997)의 연구에서는 다변량 판별분석모형과 (MDA), 로지트 (logit) 모형, 그리고 인공신경망 모형을 통해 추출된 결과값을 유전자알고리즘(Genetic algorithms)에 의해 찾아낸 가중치를 이용하여 통합해 본 결과 의미있는 결과를 얻었다. 위의 연구에서와 같이 다른 모형에 의해 추출된 결과들을 통합하여 하나의 결론을 도출할 경우 효과적인 통합 방법론의 적용이 매우 중요하다고 할 수 있다.

본 연구에서는 보다 정확한 부도예측모형을 구축하기 위하여 입력변수군을 달리하는 다수의 인공신경망 모형을 구축하고, 이 모형들의 결과를 효과적으로 통합함으로써 모형의 예측력 향상에 기여할 수 있는 방법론을 제시한다.

2. 실험설계

2.1 표본기업 및 변수선정

본 연구에 사용된 실험자료는 1995년부터 1997년에 이르기까지 3년간에 걸쳐 부도가 발생한 일반법인 중 제조업체 1,044개사와 동수의 건전기업으로 구성하였다. 그 결과 모형구축에 사용된 표본 기업은 약 2,088개 기업인데, 이 표본기업 중 훈련용으로 1,670개, 검증용으로 418개를 사용하였다.

본 연구에서는 1차적으로 구축한 약 90개 정도의 재무변수들을 단일변량검정 및 전문가 의견을 고려 약 50개정도로 압축하였다. 그리고 변수분석과정을 거쳐 다음과 같은 3개의 변수군을 선정하였다.

변수군 1: MDA (multiple discriminant analysis) stepwise selection 을 이용한 변수군

변수군 2: 상관분석, 요인분석 및 선택적 변수선정방법 (stepwise selection method) 등 통계분석결과와 전문가 의견을 반영한 변수군

변수군 3: 유전자 알고리즘(Genetic algorithms)을 이용하여 선정한 변수군

변수군별 선택 변수명은 <표 1>에 나타나 있다.

<표 1> 모형 구축에 사용된 변수군

변수군	선택 변수명
변수군 1	자기자본 총자산증가율 손익분기점율 유보액대 총자산비율 자기자본비율 재고자산회전율 불일치계수 지급여력도
	매출액
	재고자산증가율
	총자산증가율
	유보액대총자산비율
	경상수지비율
	불일치계수 지급여력도 업력
변수군 2	매출액 매출액증가율 금융비용대 매출액비율 손익분기점율 순금융비용대 매출액비율 유보액대 총자산비율 금융비용부담율증가분 순운전자본대 매출액 외부자금조달후 현금흐름 대 금융비용 불일치계수 지급여력도
	매출액 매출액증가율 금융비용대 매출액비율 손익분기점율 순금융비용대 매출액비율 유보액대 총자산비율 금융비용부담율증가분 순운전자본대 매출액 외부자금조달후 현금흐름 대 금융비용 불일치계수 지급여력도
	매출액 매출액증가율 금융비용대 매출액비율 손익분기점율 순금융비용대 매출액비율 유보액대 총자산비율 금융비용부담율증가분 순운전자본대 매출액 외부자금조달후 현금흐름 대 금융비용 불일치계수 지급여력도
	매출액 매출액증가율 금융비용대 매출액비율 손익분기점율 순금융비용대 매출액비율 유보액대 총자산비율 금융비용부담율증가분 순운전자본대 매출액 외부자금조달후 현금흐름 대 금융비용 불일치계수 지급여력도
	매출액 매출액증가율 금융비용대 매출액비율 손익분기점율 순금융비용대 매출액비율 유보액대 총자산비율 금융비용부담율증가분 순운전자본대 매출액 외부자금조달후 현금흐름 대 금융비용 불일치계수 지급여력도
	매출액 매출액증가율 금융비용대 매출액비율 손익분기점율 순금융비용대 매출액비율 유보액대 총자산비율 금융비용부담율증가분 순운전자본대 매출액 외부자금조달후 현금흐름 대 금융비용 불일치계수 지급여력도
	매출액 매출액증가율 금융비용대 매출액비율 손익분기점율 순금융비용대 매출액비율 유보액대 총자산비율 금융비용부담율증가분 순운전자본대 매출액 외부자금조달후 현금흐름 대 금융비용 불일치계수 지급여력도
	매출액 매출액증가율 금융비용대 매출액비율 손익분기점율 순금융비용대 매출액비율 유보액대 총자산비율 금융비용부담율증가분 순운전자본대 매출액 외부자금조달후 현금흐름 대 금융비용 불일치계수 지급여력도
	매출액 매출액증가율 금융비용대 매출액비율 손익분기점율 순금융비용대 매출액비율 유보액대 총자산비율 금융비용부담율증가분 순운전자본대 매출액 외부자금조달후 현금흐름 대 금융비용 불일치계수 지급여력도
	매출액 매출액증가율 금융비용대 매출액비율 손익분기점율 순금융비용대 매출액비율 유보액대 총자산비율 금융비용부담율증가분 순운전자본대 매출액 외부자금조달후 현금흐름 대 금융비용 불일치계수 지급여력도

2.2 모형의 구축

본 연구에서는 위에서 열거한 3 개의 변수군으로 3 개의 모형을 구축하였다. 본 연구에서 사용한 인공신경모형은 다층 퍼셉트론 (multi-layer perceptron)과 역전파 학습 (back-propagation) 알고리즘으로 입력변수와 출력변수, 그리고 하나의 은닉층(hidden layer)을 가지

는 3 층 퍼셉트론(three layer perceptron)을 사용하였다. 실험에 사용된 은닉층의 노드(node)수는 입력변수와 동 수를 사용하였다.

본 연구에서 사용된 모형의 출력층은 1 개의 노드로 구성되어 부도 (0) 와 건전 (1) 을 나타내며, 모형의 출력값은 [0.1] 범위에 존재한다. 모형 구축은 인공신경망모형 개발도구인 Neuroshell2 Version 3.0 을 사용하였다.

2.3 통합방법론

입력변수가 상이한 모형의 경우 비록 구축 방법론이 동일하다 할지라도 상이한 모형으로 보아야 한다. 본 연구에서는 동일한 기업에 대하여 모델간에 상이한 출력값을 보이는 경우에 있어서 최종 예측값을 도출하는 통합방법론을 제시한다.

본 연구에서는 세 모형에 적용한 결과 상이한 예측결과가 나오는 기업들의 경우 모형들의 결과를 비교하여 그 값이 학습에 사용된 목표 출력변수의 값인 0 혹은 1에 가까운 결과를 보이는 모형의 예측값을 최종 예측값으로 사용하였다. 이는 다음과 같이 표현될 수 있다.

$$OH_i = \text{Max}|0.5 - O_{ij}| \quad (1)$$

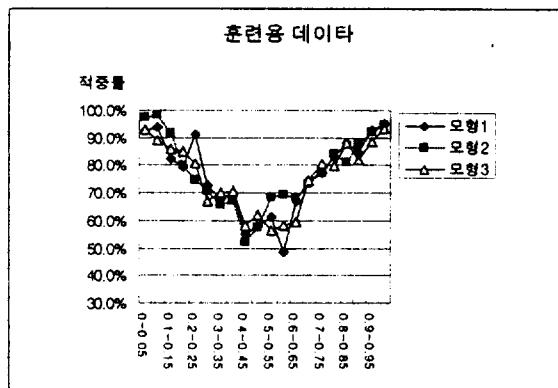
$$(i=1, \dots, n, \quad j=1, \dots, m)$$

여기서 O_{ij} 는 어떤 기업(i)의 모형별(j) 출력값이며, OH_i 는 출력값(O_{ij})과 0.5 와의 차이가 가장 큰 모형의 예측값이다. 예를 들어 어떤 기업 A 를 세 개의 모형에 적용한 결과 모형 1 에서는 0.55 의 값으로 ‘건전’으로, 모형 2 의 경우 0.61 의 값으로 ‘건전’으로, 모형 3 에서는 0.09 의 값으로 ‘부도’로 분류되었다고 하자. 위와 같이 세 개 모형의 예측값이 상이할 경우 0 혹은 1에서 가까운 결과값을 보이는 모형 3 의 예측값을 최종 예측값으로 본다는 것이다. 위와 같은 방법론을 제시하는 것은 어느 기업의 예측값이 0 혹은 1에 가까울수록, 혹은 0.5 에서 멀어질수록 해당 모형에 의해 더욱 신뢰성있게 분류되고 있다고 볼 수 있기 때문이다. 비록 2 개의 모형이 건전으로 분류하긴 하였으나 출력값이 0.55 와 0.61 으로 목표 출력값인 0 과 1에서 멀리 있다는 사실은 2 개의 모형이 해당 기업에 대해 확신을 가지지 못하고 있는 것으로 볼 수 있으므로, 해당 기업에 보다 확신을 보이는 모형 3 의 예측값을 최종 예측값으로 사용하는 것이다.

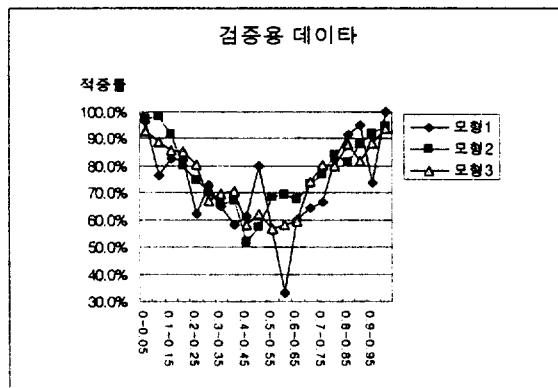
3. 실험결과 및 분석

3.1 인공신경망 출력값의 분포별 적중률

다음 <그림 1>은 인공신경망의 출력값 분포별 적중률을 보여준다. 주목할만한 점은 0.5를 분기점으로 하여 부도와 건전을 분류할 경우 모형의 출력값인 0과 1에 가까운 경우의 적중률은 매우 높은 반면 0.5 부근의 기업들은 매우 낮은 적중률을 보인다는 점이다. 출력값이 0.5 근처라는 의미는 부도의 특성과 건전의 특성 중 어느 한쪽을 강하게 가지지 못하고 있다고 볼 때 이는 예상된 것이다. 이러한 현상은 검증용 자료에서도 동일하게 발견되고 있다. 이는 어느 기업을 모형에 적용하였을 때 출력값이 0 혹은 1에 가까울수록 그 예측정보에 대한 신뢰도가 높다는 사실을 검증해 준다.



(a) 훈련용 자료



(b) 검증용 자료

<그림 1> 인공신경망 출력값 분포별 적중률

3.2 모형간의 예측결과 비교

다음 <표 2>는 3개의 모형을 통해 나온 결과가 얼마나 일치하는지, 또는 상이한지를 보여준다. 입력변수만을 달리하는 3개의 인공신경망 모형의 경우 18.6 %가 동일한 기업에 대하여 다른 결론을 내리고 있다. 이는 검증

용 자료에서도 동일하게 나타나고 있다.

<표 2> 모형간의 예측결과 비교

(a) 훈련용 자료 (cut-off: 0.5)

모형 1	모형 2	모형 3	빈도	%
부도	부도	부도	708	42.4 81.4
정상	정상	정상	652	
부도	정상	부도	38	
부도	정상	부도	56	
부도	정상	정상	45	
정상	부도	부도	71	
정상	부도	정상	83	
정상	정상	부도	17	
계		1,670	100.0	100.0

(b) 검증용 자료

(cut-off: 0.5)

모형 1	모형 2	모형 3	빈도	%
부도	부도	부도	167	40.0 81.4
정상	정상	정상	173	
부도	정상	부도	12	
부도	정상	부도	12	
부도	정상	정상	11	
정상	부도	부도	16	
정상	부도	정상	21	
정상	정상	부도	6	
계		418	100.0	100.0

3.3 적중률

<표 3> 은 상이한 예측결과를 보이는 기업군의 모형을 통한 적중률을 보여주고 있다. 여기서 주목할만한 사실은 모형간에 상이한 예측결과를 보이는 기업군의 적중률이 매우 낮다는 것이다. 실험결과 상이한 예측결과를 보이는 기업군의 경우 훈련용, 검증용 자료 공히 50% 대의 낮은 적중률을 보여주고 있다. 반면 동일한 결과를 보이는 기업군의 적중률은 80% 대를 보이고 있다.

<표 3> 모형별 적중률

(a) 상이한 결과를 보이는 기업군의 적중률

	훈련용(%)	검증용(%)
모형 1	53.9	51.3
모형 2	49.7	53.8
모형 3	50.3	52.6
통합모형	57.1	61.5

(b) 동일한 결과를 보이는 기업군의 적중률

	훈련용(%)	검증용(%)
모형 1	82.0	
모형 2		
모형 3		
통합모형		79.1

(c) 전체기업의 적중률

	훈련용(%)	검증용(%)
모형 1	76.8	73.9
모형 2	75.9	74.4
모형 3	76.1	74.2
통합모형	77.4	75.8

위의 결과는 통합모형의 적중률이 단일모형에 비해 7.7%에서 10.2% 정도 상승하는 것을 보여주고 있다. 이는 보다 신뢰성 있는 결과를 보여주는 모형의 예측값을 택함으로써 얻어진 것으로 보인다. 그 결과 전체기업의 적중률을 73.9 - 74.4% 수준에서 75.8%로 향상시키고 있다.

4. 결론

재무모형의 구축은 궁극적으로는 입력변수 간의 연관관계를 찾고, 표현하는 과정이다. 기업이 도산에 이르기까지는 많은 변인들이 매우 다양하게 작용한다. 이러한 변인들을 한 모형에 모두 반영하는 것은 가능하지도 바람직하지도 않다. 모형 구축에 있어서 너무 많은 입력변수를 사용할 경우 인공신경망 모형의 수렴(convergence)과 일반화(generalization) 모두에 부담을 준다. 게다가 재무변수들 간에 존재하는 상관관계는 다중공선성문제(multicollinearity)를 유발할 위험을 항상 내포한다.

본 연구는 단일 모형의 한계점을 다 모형의 통합을 통하여 완화 시키고자 시도하였다. 저자들은 모형의 출력값과 목표 출력값과의 근사도를 그 모형이 해당 사례기업에 대하여 얼마만큼의 확신을 가지는가 하는 지표로 보았다. 만일 개별 모형들이 서로 다른 예측결과를 보일 경우 이 지표에 의해 보다 확신을 가지고 있다고 보이는 모형의 결과를 적용하였다. 동일한 기업에 대해 발생하는 근사도의 차이는 다른 입력변수들을 적용함으로써 한기업을 다른 각도의 시각으로 보는 데서 비롯된 것으로 보인다.

본 연구는 변수군의 선정이 다소 자의적으로 이루어진 점, 향상된 성과에 대한 통계적 검증을 제시하지 않은 점 등 몇가지 한계점을 가지고 있다. 이는 추가적인 연구를 통해 보완할 예정이다.

참고문헌

이건창, 김명종, 김혁 (1994), "기업도산예측을 위한 귀납적 학습지원 인공신경망 접근방법: MDA, 귀납적 학습방법, 인공신경망 모형과의 성과비교,"

경영학연구, 23(2), pp.109-144.

이재식, 차봉근(1996), "인공신경망 학습단계에서의 Genetic Algorithm을 이용한 입력변수 선정," 한국경영과학회 추계학술대회 발표논문집, pp. 27-30.

이재식, 한재홍 (1995), "인공신경망을 이용한 중소기업도산예측에 있어서의 비재무정보의 유용성 검증," 한국전문가시스템학회지, 1(1), pp. 123-134.

한인구, 신경식 (1998), "지능형 중소기업 신용평가 모형 개발," 한국경영학회 춘계학술대회 발표논문집, pp.307-310.

한인구, 조홍규, 신경식 (1997), "The hybrid systems for credit rating," 한국경영학회지, 22 (3), pp.163-173.

Barniv, R., Agarwal, A. and Leach, R. (1997), "Predicting the outcome following bankruptcy filing: A three-state classification using neural networks," *Intelligent Systems in Accounting, Finance and Management*, 6, pp.177-194.

Bell, T. (1997), "Neural nets or the logit model? A comparison of each model's ability to predict commercial bank failures," *Intelligent Systems in Accounting, Finance and Management*, 6, pp.249-264.

Boritz, J. and Kennedy, D. (1995), "Effectiveness of neural networks types for prediction of business failure," *Expert Systems with Applications*, 9, pp.503-512.

Chung, H. and Tam, K. (1992), "A comparative analysis of inductive learning algorithm," *Intelligent Systems in Accounting, Finance and Management*, 2, pp.3-18.

Etheridge, H. and Sriram, R. (1997), "A comparison of the relative costs of financial distress models: Artificial neural networks, logit and multivariate discriminant analysis," *Intelligent Systems in Accounting, Finance and Management*, 6, pp.235-248.

Fletcher, D. and Goss, E. (1993), "Forecasting with neural networks: An application using bankruptcy data," *Information and Management*, 24(3), pp.159-167.

Jo, H., Han, I. And Lee, H. (1997), "Bankruptcy prediction using case-based reasoning, neural networks, and discriminant analysis," *Expert Systems With Applications*, 13 (2), pp.97-108.

Kun Chang Lee, Ingoo Han, Youngsig Kwon (1996), "Hybrid neural network models for bankruptcy predictions," *Decision Support Systems*, (18)1, pp. 63-72

Odom, M. and Sharda, R. (1990), "A neural networks model for bankruptcy prediction," *Proceedings of the IEEE International Conference on Neural Network*, Vol.2, pp.163-168.

Salchenberger, L., Cinar, E. and Lash, N. (1992), "Neural networks: A new tool for predicting thrift failures," *Decision Sciences*, 23, pp.899-916.

Tan, K. and Kiang, M. (1992), "Managerial applications of neural networks: the case of bank failure predictions," *Management Science*, 38(7), pp.926-947.

Wilson, R. and Sharda, R. (1994), "Bankruptcy prediction using neural networks," *Decision Support Systems*, 11(5), pp.545-557.