

인공신경망모형을 이용한 국제곡물 조기경보지수 개발*

김종진** 김지연***

Keywords

조기경보지수(early warning index), 인공신경망모형(artificial neural network model), 국제곡물시장(world grain market)

Abstract

Using the Artificial Neural Network model which is known as an excellent tool for perception of data patterns and short-run forecasting, this study develops an early warning index for the world grain markets. To obtain the best result, this study compares the indices which are computed from the different specifications of output neurons in our neural networks. The final result of this comparison shows that the best early warning index can be derived when we use the most aggregate variables and include all leading variables between present and targeted forecasting time as output neurons in our networks. We also verified that the index form of this study shows much better performances in the view of prediction power when we compare the index with the existing indices from other studies.

차례

1. 서론
2. 인공신경망모형의 이론적 배경
3. 위기지수 및 데이터
4. 인공신경망 구조식별
5. 조기경보지수 산출
6. 결론

* 본 연구는 2014년 수행된 한국농촌경제연구원 관측센터의 「국제곡물 관측 시스템 구축」 과제의 연구내용 일부를 수정·보완하여 논문으로 제작성한 것임.

** 한국농촌경제연구원 연구위원, 교신저자. e-mail: jkim@krei.re.kr

*** 한국농촌경제연구원 연구원.

1. 서론

1960년대 이후 밀, 옥수수, 콩, 쌀 등 주요 곡물의 국제가격은 두 번의 급등기를 거쳤다. 1970년대 초의 국제곡물 위기는 농업부문의 투자증대와 각국의 지원정책에 힘입어 1970년대 중반부터 세계 곡물 재고량이 점차 증가하면서 안정되기 시작하였다. 이후부터 2000년대 중반까지 30년간 주요 곡물의 국제가격은 평균과 분산이 거의 일정하게 유지되는 안정적인 추이를 보였다.¹ 곡물 국제가격의 안정적인 추이는 2007~08년 세계 식료품 가격위기²를 계기로 또다시 급등하였는데 곡물 국제가격 수준이 2배 이상 상승하였을 뿐만 아니라 변동성도 크게 증가한 모습을 보였다. 주요 곡물 국제가격의 이러한 추이변화는 중국, 인도 등 거대 신흥국의 경제성장에 따른 식용 및 사료용 곡물 소비증대와 세계적인 바이오연료 생산 확대에 의한 수요증대가 그 원인인 것으로 알려져 있다. 거대 인구를 가진 신흥국의 부상과 바이오연료 생산 확대가 지속될 것으로 예상되며, 단기적으로 곡물 생산량을 크게 증대시키는 것이 사실상 불가능할 것으로 보이기 때문에 곡물 국제가격의 높은 수준과 큰 변동성은 당분간 유지될 것으로 전망되는 상황이다.

쌀 이외의 밀, 옥수수, 콩 등의 곡물을 거의 전량 수입에 의존하는³ 우리나라는 곡물 국제가격의 높은 수준 유지와 변동성 확대의 영향을 직접적으로 받게 된다. 2000년 이후 우리나라는 매년 비슷한 규모의 곡물을 수입해 오고 있는 데 반해 수입액은 곡물가격에 따라 큰 변동성을 보인다. 2013년 기준 우리나라 곡물 수입액은 약 6조 4천억 원에 이르는 것으로 나타났다. 즉, 곡물 국제가격이 10% 상승하면 약 6천 4백억 원의 추가적인 수입대금 지급액이 늘어나는 것으로 계산된다.⁴ 국제곡물 가격 추이가 안정적이었던 2000년대 중반 이전까지 우리나라 곡물 총수입액은 2조~3조 원에 지나지 않았다. 수입곡물 가격 상승은 이를 원료로 하여 생산되는 밀가루, 빵, 국수 등 가공식품

1 명목가격의 평균과 분산이 일정하다는 의미이며 실질가격은 농업기술 발전에 따른 단수의 증대로 단위 생산비가 하락하면서 하락하는 추이를 보였다.

2 2000년대 중반의 가격 급등은 Merrill Lynch의 2007년 보고서인 ‘Global Agriculture & Agflation’에서 ‘에그플레이션’이라 명명하였다. 에그플레이션으로 대부분의 선진국에서 식료품가격이 급등하였으며 일부 저개발국에서는 식료품가격 폭등으로 정치 및 경제적 불안정성이 심화되어 시위와 폭동이 발생하였다. 이러한 식료품 가격 급등의 파급영향은 이후 식량안보에 대한 국제적 관심을 증대시키는 역할을 하였다.

3 우리나라 곡물 자급률은 밀과 옥수수의 경우 1% 미만이며 콩도 10%를 넘지 못할 정도로 매우 낮은 상황이다.

4 김중진 외(2014: 11-12).

물가 인상의 요인으로 작용할 뿐만 아니라 사료가격 인상을 통해 축산물 가격에도 전이된다. 식품물가의 상승은 국가경제에 미치는 전반적인 악영향에 더하여 취약계층이라 할 수 있는 저소득 계층에 특히 심각한 영향을 미쳐 여러 가지 사회문제를 심화시킬 수 있다. 이러한 이유로 세계 식료품 가격위기 이후 곡물 국제가격의 불안정성에 대응하기 위한 여러 가지 대안들이 제시되어왔다. 국제곡물 조기경보시스템(Early Warning System) 구축은 이러한 노력의 일환으로 국제곡물 가격변동을 미리 예측하여 그 영향을 최소화할 수 있는 시스템을 만드는 것이다.

1997년 IMF 외환위기와 2003년의 금융위기를 거치면서 위기관리의 중요성을 인지한 정부가 종합적인 국가 위기관리체계를 수립하여 추진한 것이 우리나라에서 조기경보시스템이 구축되기 시작한 계기가 되었다. 이후 여러 분야에 조기경보시스템이 마련되었으며 사회·경제 분야의 경우 금융, 대외, 석유, 부동산, 원자재, 노동 등에 조기경보시스템이 구축되어 운영 중이다.⁵ 또한 국제곡물 분야도 김태훈·송준호(2009)의 연구⁶를 바탕으로 조기경보시스템이 구축된 바 있다. 다양한 분야에 구축되어 운영 중인 우리나라 조기경보시스템은 경보단계 판단을 위한 조기경보지수(Early Warning Index)의 산출모형으로 일반회귀식모형, 신호접근모형, 프로빗/로짓모형을 주로 사용하고 있다. 김종진·김지연(2016)은 이상의 세 가지 모형을 국제곡물 분야에 적용하여 각 모형의 성과를 비교한 결과 모수적 접근방법(parametric method)인 일반회귀식모형과 프로빗모형의 성과가 국내에 구축된 조기경보시스템에서 가장 많이 사용되고 있는 비모수적 접근방법(non-parametric method)인 신호접근 모형에 비해 우수한 성과를 보임을 입증하였다. 본고에서는 석유 분야 조기경보시스템에 응용된 바⁷ 있는 인공신경망모형(artificial neural network model)을 국제곡물 조기경보시스템에 적용하는 방안을 제시하고 이의 성과를 김종진·김지연(2016)의 연구에서 제시한 세 가지 모형의 성과와 비교하고자 한다. 모형 성과의 직접적 비교라는 연구목적을 달성하기 위해 국제곡물 분야 위기의 정의, 위기지수 산출방법, 이용 자료 등을 김종진·김지연(2016)과 동일하게 하였다.

인공신경망모형은 사물 인지가 이루어지는 인간의 중추 신경망 체계를 모사한 정보처리 시스템이다. 사물 인지과정은 신경 세포인 뉴런과 이들을 연결하는 시냅스로 이루어져 반복적 경험을 통한 학습이 뉴런들의 연결강도로 축적되는 형태인데, 인공신경

5 현재 사회·경제 부문에만 10개의 조기경보시스템이 구축되어 운영 중인 것으로 파악된다.

6 김태훈·송준호(2009)의 연구는 국제곡물 분야에 조기경보지수를 개발한 최초의 연구이나 위기를 세계 곡물시장이 아닌 국내 수입단가를 기준으로 정의하여 개발된 조기경보지수의 유용성이 떨어지는 한계를 가진다.

7 윤덕룡 외(2004).

망모형은 이처럼 반복적 학습을 통해 패턴을 찾아내고 이를 이용해 미래를 예측하는 방법이라 할 수 있다. 여타 경제학 혹은 통계학적인 모형에서 요구하는 가정에 근거하지 않고 데이터를 통한 학습으로 현실의 다양한 패턴을 인지하여 일반적으로 여타 통계학적 모형에 비해 뛰어난 예측능력을 보이는 것으로 알려져 있다. 특히, 계량경제학 혹은 통계학적 시계열 분석모형은 비교적 단순한 선형함수의 추정을 통해 미래를 예측하여 비선형적인 특성을 보이는 자료의 예측에 한계를 보여 왔다. 또한 패턴 인식이 뛰어난 인공지능망모형의 장점으로 인해 새로운 형태의 위기 예측이라는 측면에서 기존의 다른 모형에 비해 뛰어날 것으로 판단되어 조기경보시스템 구축에 활용성이 높은 것으로 평가되고 있다.

인공지능망모형은 이미 다양한 분야의 조기경보시스템 구축 연구에 응용되고 있다. 특히 윤덕룡 외(2004)의 연구를 기반으로 구축되어 운영 중인 석유 부문의 조기경보시스템이 대표적이라 할 수 있다. 윤덕룡 외(2004)는 석유시장 위기를 설명하는 입력층 노드(변수)로 두바이 유가 관련 6개 변수⁸와 원유의 수급 관련 6개 변수 및 국제금융시장 관련 6개 변수를 사용하였으며 출력변수로는 실질유가영향지수⁹를 5단계의 위기 수준으로 구분하여 사용하였다. 또한 이의 후속연구라 할 수 있는 Song(2010)의 연구에서는 인공지능망모형의 결과를 프로빗모형의 결과와 비교하여 인공지능망모형의 우수성을 입증하였다. 인공지능망모형을 조기경보시스템에 활용한 여타 예로는 서하나(2009, 여신관리), 강용진(2011, 추가), Kim 외(2009, 금융), Oh 외(2006, 금융) 등의 연구들이 존재한다.

조기경보모형의 우수성은 결국 조기경보지수의 예측력과 선행성 정도에 의해 결정된다고 할 수 있다. 조기경보지수는 해당 분야 위기의 정의를 바탕으로 한 위기지수(crisis index)를 예측하는 것으로, 위기지수의 작성방법에 따라 다양한 예측방안이 존재할 수 있다. 본 연구는 인공지능망모형을 이용하여 여러 가지 대안적 방법으로 조기경보지수를 작성하고 이러한 작성방법에 따른 예측력의 차이를 비교하여 국제곡물 조기경보시스템에 적용 가능한 최선의 대안을 도출하고자 한다.¹⁰

8 모형의 효율성 개선을 위하여 원자료의 3개월 이동평균, 전월 혹은 3개월 전 대비 증가율 등을 변수로 사용하였다.

9 실질유가영향지수는 윤덕룡 외(2004)의 연구에서 위기지수로 사용한 것으로 유가가 국내 경제에 미치는 영향과 중요성을 감안하기 위하여 실질국제유가에 석유원단위(=석유소비량/불변가격 GDP)를 곱한 값으로 계산하였다.

10 Song(2010) 연구가 조기경보시스템 구축에서 인공지능망모형이 여타 모형에 비해 우수한 성과를 보인다는 것을 증명하고 있으므로 본 연구는 여타 모형 간 성과비교보다는 다양한 대안적 인공지능망 구성을 검토하여 곡물 분야에 적용 가능한 최선의 대안을 식별하는 데 주안점을 둔다.

2. 인공신경망모형의 이론적 배경

인공신경망모형은 데이터를 통해 학습된 다양한 패턴을 기반으로 예측 결과를 도출하여 복잡한 비선형 함수형태를 보이는 변수들의 예측에 특히 우수한 성능을 발휘하는 것으로 알려져 있다. 이러한 인공신경망모형의 장점으로 인해 공학 분야를 비롯해 경영학의 재무 및 정보시스템, 계량경제학 분야에 이르기까지 활용 분야가 크게 확대되어 왔다(윤덕룡 외 2004). 특히, 최근에는 계량경제학적 방법론의 한계를 극복하는 대안으로 금융공학 또는 재무경제학자들은 주가, 환율, 부도, 채권평가, 금리 등의 예측에서 인공신경망모형의 유용성에 대해 주목하고 있다. 그러나 인공신경망모형은 입력 자료가 은닉층(hidden layer)이라고 불리는 모형의 내부적 망 공간에서 학습을 통해 결과물을 도출하기 때문에 입력변수 간의 상호작용을 설명할 수 없을 뿐만 아니라 각 입력변수의 결과에 대한 기여도를 명시적으로 나타낼 수 없다는 한계를 가진다. 또한 장기적 균형관계를 설명하는 경제학적 이론에 기반한 모형이 아니기 때문에 중장기 예측에서는 일반적으로 계량 경제학적 모형에 비해 좋은 성과를 나타내지 못하는 것으로 알려져 있다. 따라서 인공신경망 모형은 각 입력변수의 결과에 대한 기여 및 설명력의 정도를 파악하기보다는 정확한 단기 예측치가 필요한 경우에 적합한 모형이라고 할 수 있다.

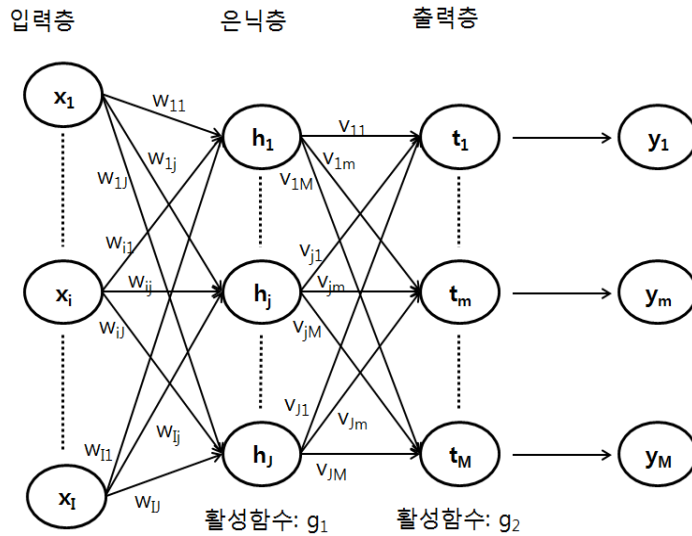
인공신경망모형은 변수들 간의 패턴인식을 위하여 인간 두뇌의 사물 인지 과정을 모사하는 비선형 분석모델로 인간의 신경망 구조를 모방한 입력층(input layer), 은닉층(hidden layer) 및 출력층(output layer)으로 구성된다. 입력층의 자료는 가중치에 따라 합산하여 은닉층에서 활성화함수(activation function)에 의해 변환되는 과정을 반복한 후 출력층으로 보내지는 구조로 학습이 진행된다. 인공신경망이 여타 통계학적 방법들과 구분되는 가장 큰 특징은 입력층과 출력층 사이에 존재하는 은닉층으로, 은닉층 수 및 각 은닉층의 노드(혹은 neurons) 수를 조정¹¹하여 모형의 적합도(fitting)를 높일 수 있다. 인공신경망모형에서의 학습은 이러한 각 층의 노드 수와 노드들 간의 연결강도를 나타내는 가중치를 조정하여 예측오차를 최소화하는 것을 의미한다.

<그림 1>은 k 개의 입력층 노드(x_i), 1개의 은닉층 및 J 개의 은닉층 노드(h_j), M 개의 출력층 노드(t_m)를 갖는 인공신경망모형의 개념도이다. 입력층의 값들은 은닉층의 각

¹¹ 인공신경망은 은닉층이 여러 개 존재할 수 있기 때문에 다층 퍼셉트론(multilayer perceptron)으로 불리기도 한다.

노드로 보내지는데, 이때 연결강도를 나타내는 가중치는 w_{ij} 로 표현되어있다. 즉, 입력 층의 정보(x_i)는 은닉층의 노드 j 에서 $h_j = \sum_{i=1}^I w_{ij}x_i + w_{0j}$ 로 취합된다. 이렇게 취합된 정보는 은닉층의 활성화 함수(g_1)에 의해 변형된다. 은닉층 j 에서 집계 및 변형된 값($g_1(h_j)$)은 다시 출력층의 m 노드들로 v_{jm} 의 연결강도로 보내진다. 출력층에 도달한 정보는 은닉층에서와 동일한 방식으로 집계($t_m = \sum_{j=1}^J v_{jm}h_{jm} + v_{0m}$) 및 변형($g_2(t_m)$)되어 최종 출력치를 생성하게 된다. 여기서 w_{0j} 와 v_{0m} 는 바이어스(bias)를 나타내는 것으로 회귀식의 상수항과 같은 역할을 한다.

그림 1. 인공신경망모형의 구조



활성화함수를 나타내는 g_1 은 $R^{I+1} \rightarrow R$ 인 함수이며 g_2 는 $R^{J+1} \rightarrow R$ 인 함수로 다양한 형태의 함수를 사용할 수 있다. 그러나 많은 경우 누적정규분포 함수나 로지스틱 함수에서와 같이 h_j 의 출력 노드 값(t_m)에 대한 한계효과(marginal effect)가 특정 구간에서는 크나 이 구간을 벗어날 경우 작아질 수 있다는 가정을 바탕으로 S-자 형태의 함수를 주로 사용하게 된다. 본 연구에서는 은닉층의 활성화함수로 로지스틱 함수를 사용하고 출력층에서는 다음과 같은 선형함수를 사용하였다.

- (1) 로지스틱 활성화함수: $g(z) = \frac{1}{1 + \exp(-z)}$
- (2) 선형 활성화함수: $g(z) = z$

출력층의 활성화함수 g_2 는 출력 값을 0과 1 사이로 제한할 필요가 있는 경우 로지스틱 함수를 사용하고 그렇지 않은 경우 선형함수가 주로 이용된다.

인공신경망모형은 각 노드들의 연결강도를 나타내는 가중치뿐만 아니라 은닉층의 수와 노드 수를 조정하여 목적함수(objective function)¹²를 최적화시키는 학습과정을 거치게 된다. <그림 1>에서와 같이 I 개의 데이터, M 개의 출력 노드, 1개의 은닉층 및 J 개의 은닉층 노드를 갖는 망에서의 학습은 목적함수를 나타내는 아래 식 (1)의 잔차차승합(Sum of Squared Error: SSE)을¹³ 최소화하는 가중치(w_{ij} 및 v_{jm})를 찾는 최적화 과정으로 볼 수 있다.

$$\begin{aligned}
 (3) \quad SSE &= \sum_{n=1}^N \sum_{m=1}^M (y_{mn} - g_2(t_{mn}))^2 \\
 &= \sum_{n=1}^N \sum_{m=1}^M (y_{mn} - g_2(\sum_{j=1}^J v_{jm} h_{jn} + v_{0m}))^2 \\
 &= \sum_{n=1}^N \sum_{m=1}^M (y_{mn} - g_2(\sum_{j=1}^J v_{jm} g_1(\sum_{i=1}^I w_{ij} x_{in} + w_{0j}) + v_{0m}))^2
 \end{aligned}$$

인공신경망모형에서의 학습과정은 통상적인 비선형모형의 최적화 과정과 비슷하나 은닉층의 존재로 순차적인 최적화 과정을 따르게 되며 최적화 과정의 효율성을 높이기 위한 다양한 알고리즘이 사용된다. ‘back-propagation’ 알고리즘은 전통적으로 가장 많이 사용되는 최적화 알고리즘으로 출력층에 가까운 가중치를 먼저 조정(update)하고 이후 입력층에 가까운 쪽 가중치를 조정하는 방식으로 학습을 진행한다. ‘back-propagation’ 알고리즘의 학습규칙(learning rule)은 $w_k^{(r+1)} = w_k^r - \eta \nabla SSE(w_k^{(r)})$ 로 나타낼 수 있다. 여기서 r 은 조정 횟수, $\eta \in (0,1)$ 는 학습률(learning rate), k 는 노드를 각각 나타내며 $\nabla SSE(w^{(r)})$ 은 목표함수의 편미분(gradient) 값을 나타낸다. 인공신경망모형은 대부분 다수의 입력층 및 출력층과 노드를 가고 있어 이의 최적화를 나타내는 학습에는 많은 계산 자원과 시간이 필요하며 이러한 시간과 자원을 줄이기 위한 다양한 알고리즘이 개발되어왔다. 학습 속도와 효율성을 높인 ‘resilient backpropagation with (Riedmiller 1994) or without(Riedmiller and Braun 1993) weight backtracking’, ‘globally convergent

¹² 주로 비용함수(cost function)이라 불리며 주로 계산된 값과 실측치와의 차이를 나타내는 함수식을 사용한다.

¹³ 출력변수가 0과 1의 질적 변수일 경우 Cross-Entropy를 목표함수로 설정하기도 한다. Cross-Entropy는 $CE = \sum_{n=1}^N \sum_{m=1}^M (y_{mn} \log(t_{mn}) + (1 - y_{mn}) \log(1 - t_{mn}))$ 로 정의된다.

version(Anastasiadis et al. 2005)' 등의 알고리즘이 최근 많이 사용되고 있다. 본 분석에 주로 사용된 'resilient backpropagation'은 학습규칙에 각 가중치에 따라 다른 학습률(η_k)를 사용하며 목표함수의 편미분 값의 부호만을 사용한다는 것에서 기존의 'back-propagation' 알고리즘과 차이가 있다. 따라서 'resilient backpropagation' 알고리즘의 학습규칙은 $w_k^{(r+1)} = w_k^r - \eta_k \text{sign}(\nabla SSE(w_k^{(r)}))$ 로 표현된다.

최적 인공신경망 식별을 위해서는 학습 알고리즘 이외에도 은닉층의 수, 각 층의 노드 수 등을 결정해야 하는 문제가 존재한다. 현재까지 신경망 내의 은닉층 수나 각 은닉층 내의 노드 수를 결정하는 최적의 방법에 대한 일치된 견해는 존재하지 않으나 주로 학습 및 예측의 성과를 이용하거나 AIC/BIC(Akaike's Information Criterion/Bayesian Information Criterion) 기준을 사용한다. 또한 입력변수들의 평균과 분산 등을 이용한 표준화된 변수를 사용할 경우 학습의 효율성이 증대되거나 적합도를 높일 수 있는 것으로 알려져 있다.

본 연구에서 사용된 최적 인공신경망 망구조 식별 및 학습 기준 설정은 조기경보지수 작성의 가장 중요한 과제가 표본기간 내에서의 적합도보다는 표본기간 이외의 구간에 대한 예측력 높은 모형의 식별이라는 관점에서 표본 외 자료에서의 예측력을 기준으로 망구조를 식별한다. 이를 위해 표본자료를 5개월 단위로 구분한 후 앞의 4개 자료를 학습자료(in-sample)로 사용하고 마지막 1개 자료를 검증자료(out-of sample)로 분리하였다. 학습자료와 검증자료로의 구분은 인공신경망모형에서 흔히 제기되는 과적합(over-fitting)¹⁴ 문제를 해결하기 위함이기도 하다. 즉, 은닉층 수와 노드 수를 늘리거나 최적화의 임계치(threshold)를 작게 함으로써 학습에서의 적합도를 용이하게 높일 수 있으나 이 경우 관측 값에 특유한 잡음신호까지 모형 내에 고려하게 되어 학습자료 이외의 구간에 대한 예측력이 오히려 낮아지는 경우가 발생한다. 본 연구에서는 검증자료에서의 예측력을 기준으로 망구조 및 학습기준을 식별하였다. 이는 과적합 문제해결을 위한 추가적인 고려를 하지 않아도 될 뿐만 아니라 조기경보지수가 요구하는 예측력 증대라는 두 목적을 동시에 달성할 수 있게 한다.

예측치와 실측치 간의 차이 즉, 예측력을 검증하는 지표는 예측치와 실측치의 오차를 실측치에 대한 백분율 개념으로 계산하여 해석이 용이한 RMSPE(Root Mean

¹⁴ 인공신경망모형은 은닉층과 노드 수를 조정함으로써 학습자료 내에서 거의 완전한 적합(fitting)을 나타내도록 할 수 있으나 이 경우 학습자료 외에서 예측력이 떨어지는 문제가 발생한다. 이러한 과적합 문제는 목적함수(비용함수)에 노드 및 은닉층을 추가하는 것에 대해 벌점을 부과하는 Regularization method와 과적합이 발생하지 않도록 가중치 update를 조기에 중지시키는 early stopping 방법이 주로 사용된다.

Squared Percent Error)를 사용하였다. 즉, 최종 망구조 및 학습 기준은 학습 결과를 바탕으로 검증자료에 대해 예측된 결과와 실측값으로 RMSPE를 계산하여 가장 우수한 성과(최솟값)를 내는 망구조 및 학습 기준을 최종 확정하였다.¹⁵

$$(4) \quad RMSPE = \sqrt{\frac{1}{T} \sum_{t=1}^T \left(\frac{\hat{y}_t - y_t}{y_t} \right)^2}$$

3. 위기지수 및 데이터

3.1. 위기지수 및 조기경보지수

통상의 조기경보모형은 위기 수준을 평가하기 위한 위기지수(crisis index)와 이러한 위기지수에 선행하여 움직이는 조기경보지수(early warning index)로 구성된다. 위기지수는 해당 분야의 위기 여부를 판단하기 위한 정량적 지표로 위기에 대한 정의를 바탕으로 작성된다. 본고에서는 국제곡물시장의 위기를 ‘국내에 주로 수입되는 주요 곡물의 국제가격이 안정적인 상태를 벗어나 국내물가에 상당한 파급영향이 우려되는 경우’로 정의하였다.¹⁶ 구체적으로 위기지수는 아래의 산식을 사용하여 도출하였다.

$$(5) \quad \text{위기지수(CI: Crisis Index): } CI_t = 0.5 \times P_t + 0.5 \times \left(\frac{P_t}{P_{t-12}} - 1 \right) \times 100$$


여기서 P_t 는 주요 국제곡물 FOB 가격지수로 $100 \times \left(\frac{\sum_{i=1}^4 w_i P_{i,t}}{\sum_{i=1}^4 w_i \cdot P_{i,2000.1}} \right)$ 로 계산된다. $P_{i,t}$ 는 t 시점 i 곡물(밀, 옥수수, 콩, 쌀) 가격이며, w_i 는 i 곡물의 가중치로

¹⁵ RMSPE 이외에도 MAE(mean absolute error) = $\frac{1}{T} \sum_{t=1}^T |\hat{y}_t - y_t|$, RMSE(root mean squared error) = $\sqrt{\frac{1}{T} \sum_{t=1}^T (y_t - \hat{y}_t)^2}$ 등의 기준을 사용할 수 있다. 그러나 이 경우 계산된 값들에 대한 직관적 해석이 어렵다는 단점이 있다.

¹⁶ 위기의 정의 및 위기지수의 작성방법, 위기구간 설정 등은 김종진 외(2014) 및 김종진·김지연(2016)의 연구와 동일하게 하였다.

최근 3개년간의 국내 수입액 비중(밀, 옥수수, 콩, 쌀)이 각각 0.276, 0.429, 0.235, 0.060)을 나타낸다. 위 식에서와 같이 국제곡물 시장의 위기지수는 주요 국제곡물 FOB(Free On Board)가격과 이들의 전년 동기 대비 증감률을 동일한 가중치로 합산한 것으로 산정하였다. 이는 절대적 가격 수준이 높지 않은 경우에도 전년 동기 대비 증가율이 큰 경우 큰 폭의 식품 및 사료물가 상승이 우려되는 만큼 국제곡물 시장의 위기로 간주될 수 있다는 측면을 반영하기 위한 것이다.¹⁷ 이렇게 작성된 위기지수를 바탕으로 표본기간 내에서의 위기구간은 주로 통계학적 방법인 위기지수의 평균(μ)과 분산(σ)을 사용한 수식 $\mu + k \times \sigma$ 을 사용하여 결정한다. 그러나 이러한 위기구간의 도출은 해당 분야 종사자와 국민들이 실제적으로 동의할 수 있어야 하며 구축하고자 하는 조기경보시스템의 취지에 맞도록 k 값을 적절히 결정하여야 한다. 본 연구에서는 $k=1$ 의 기준을 사용하였으며 표본의 대상기간은 국제곡물 가격이 상승하기 시작한 2006년 1월부터 최근(2014년 12월)까지의 9년간 월별 자료를 사용하였다.

그림 2. 국제곡물 가격지수와 위기구간 설정



<그림 2>는 국제곡물시장의 위기지수 및 위기구간을 식별한 결과를 보여준다. 위기구간으로 식별된 구간은 애그플레이션으로 국제곡물 가격이 크게 상승했던 2008년 1월에서 7월, 러시아의 곡물 수출금지 조치의 영향하에 있었던 2010년 12월에서 2011년

¹⁷ 자세한 국제곡물시장의 위기지수에 대한 작성방법 및 절차, 의미, 논리적 근거에 대해서는 김종진 외(2014)를 참고하기 바란다.

8월, 마지막으로 미국 등에서의 기상악화로 인해 곡물 국제가격이 역대 최고 수준을 기록한 2012년 7월부터 2013년 1월까지이다. 따라서 이상에서 설명된 위기구간을 바탕으로 구축된 조기경보시스템은 위기로 식별된 3개 구간과 비슷한 상황을 대비하는 경보시스템으로 해석될 수 있다.

본고에서 조기경보지수는 위기발생 여부를 예측하는 정량적 지표로 위기지수의 3개월 선행 예측치로 정의하였다. 즉, 위기 여부만을 예측할 경우 갖게 되는 정보의 손실과 정확한 위기 수준의 예측 값이 일정 부분 시장 참가자 및 정책 당국자들에게 정보를 제공할 수 있다는 측면에서 위기 여부가 아니라 위기지수의 예측치를 조기경보지수로 사용하였다.¹⁸ 3개월이라는 시차는 위기 징후 포착 후 대안을 마련하기에는 짧은 기간이라 할 수 있으나 더 선행 시차의 예측 값을 사용할 경우 예측력이 떨어지는 문제점이 발생한다. 곡물이 해외에서 구매되어 국내에 도입되는 데 통상적으로 4~6개월의 시차가 발생한다는 점을 고려하면 곡물이 국내에 반입되기까지 7~9개월간의 시간이 존재하여 충분하지는 않지만 적지 않은 시간적 여유가 존재한다고 할 수 있다.

3.2 데이터 및 입력층 노드

<표 1>은 본 연구에서 입력층의 노드로 사용된 설명변수들을 보여준다.¹⁹ 입력층 노드의 변수는 원자료 이외에 필요하다고 판단될 경우 6개월 이동평균값 및 과거 시차변수를 추가로 생성하여 총 45개의 입력층 노드(변수) 수를 가지게 되었다. 인공신경망모형은 시계열 모형과 달리 과거 시차변수가 체계적으로 고려되지 않는다. Song (2010) 등의 선행연구의 경우 시차변수 대신 3개월 혹은 6개월 이동평균 값 등을 주로 사용하였다. 이렇게 원자료를 변환한 변수를 추가하는 것은 인공신경망모형의 적합도와 예측력을 높이기 위함이다.

¹⁸ 신호접근모형과 프로빗/로짓모형의 경우 위기지수를 사용하여 위기 여부를 판단한 후 위기 여부를 나타내는 이항변수를 예측하는 접근법을 사용한다. 이 경우 위기의 발생 여부에 집중하여 모형이 설계된다는 측면은 있으나 통상적인 위기 수준에 대한 많은 정보가 소실될 수 있으며 이로 인해 예측력도 감소할 수 있다.

¹⁹ 본 연구에 사용된 변수는 김종진 외(2014)와 김종진·김지연(2016)의 연구에서 사용된 변수와 동일하다. 자세한 변수에 대한 설명과 이러한 변수들의 사용에 대한 이론적 근거 등은 김종진 외(2014)를 참조하기 바란다.

표 1. 인공신경망모형 입력변수

대분류	중분류	소분류
위기지수	FOB 곡물가격 (총 12개 변수)	밀, 옥수수, 콩 및 쌀의 FOB가격, 이의 전기 시차 및 6개월 이동평균
선물시장	근월 물 가격 (총 8개 변수)	밀, 옥수수, 콩 및 쌀 선물가격 및 이의 6개월 이동평균
	비상업 순매수포지션 (총 8개 변수)	밀, 옥수수, 콩 및 쌀 비상업 순매수 포지션 및 6개월 이동평균
공급요인	재고율(총 8개 변수)	밀, 옥수수, 콩 및 쌀 재고율 및 이의 6개월 이동평균
	기상 (총 2개 변수)	엘니뇨(평년 대비 해수면 평균온도 상승), 라니냐(평년 대비 해수면 평균온도 하락)
수요 및 거시경제요인	거시경제 요인 (총 6개 변수)	OECD/비OECD국 평균 환율 OECD/비OECD국 평균 GDP 성장률 OECD/비OECD국 GDP 디플레이터 변화율
	유가 (총 1개 변수)	유가 선물가격(브렌트유)

주: 위기지수는 출력층의 값(y_m)으로 사용되며 나머지 변수는 입력층 노드(x_i)로 사용됨.

이상의 입력층 노드에 사용된 변수들은 학습의 효율성을 증대시키기 위하여 아래의 식을 이용하여 표준화하였다.²⁰

$$(6) \text{ 입력층 노드(설명변수)의 표준화}^{21}: x^* = \frac{2x}{\max(x) - \min(x)} - \frac{\max(x) + \min(x)}{\max(x) - \min(x)}$$

4. 인공신경망 구조식별

본 연구는 단순히 인공신경망모형을 이용하여 조기경보지수를 작성하는 과정을 설명하기보다는 다양한 대안적 방법²²으로 조기경보지수를 작성한 후 이들 간의 비교를

²⁰ McNelis(2005) 참조.

²¹ Song(2010)의 연구에서도 동일한 방법으로 표준화하였다. 이러한 표준화 방법 이외에도 각 변수들의 평균을 0, 분산을 1로 하는 등의 다양한 방법이 사용될 수 있다. 표준화 방법 및 이에 따른 학습 효율성 변화에 대한 연구는 양승룡 외(2014)를 참고하기 바란다.

²² 인공신경망모형 이외의 신호접근모형, 프로빗모형 등의 여타 조기경보모형을 이용한 결과와 비교 분석하는 방안도 생각할 수 있으나 Song(2010) 등의 연구가 이미 인공신경망모형을 통한 조기경보지수의 작성이 여타 모형에 의한 결과에 비해 우수한 성과를 보일 수 있다는 것을

통해 가장 예측력이 높은 인공신경망모형 적용 방법을 식별하고자 한다. 조기경보지수는 위기지수의 3개월 선행예측 값으로 설정하였다. 따라서 국제곡물 분야의 조기경보지수는 위기지수를 3개월 선행하며 3개월 선행 예측력이 가장 높은 지수가 우수한 조기경보지수라 할 수 있다.

본고는 국제곡물 위기지수가 4대 주요 곡물의 가격을 수입량으로 가중한 국제곡물 가격지수(P_t)를 통해 계산되며 통상적 경제학 모형이 주로 가격 수준이나 변화율만을 예측하게 설정된다는 측면에서 ㉠ 개별 곡물가격의 3개월 선행 가격 수준($P_{i,t+3}$)을 예측하여 조기경보지수를 재구성하는 방법, ㉡ 3개월 선행 국제곡물 가격지수(P_{t+3})를 예측하여 조기경보지수를 재구성하는 방법 및 ㉢ 3개월 선행 조기경보지수(C_{t+3})를 직접 예측하는 방법의 세 가지 방안을 고려하였다. 더하여 위의 세 가지 방법 각각에 대해 ① 3개월 선행 시점만을 출력층 노드(y_{t+3})로 설정하는 방법과 ② 1~2개월 선행 시점도 출력층 노드(y_{t+1}, y_{t+2})로 추가하여 망구조를 설정하는 두 가지 방안을 고려하였다. 따라서 위의 모든 경우의 수를 고려하면 총 여섯 가지 대안적 조기경보지수 작성방법을 고려하게 된다.²³

각 대안적 방법에 대한 예측성과를 비교하기 위해서는 각 방법에 대해 인공신경망모형을 적용하여 조기경보지수를 산출하여야 한다. 각 대안적 방법에 대한 예측성과를 비교가능하게 할 수 있도록 입력층의 노드 수, 학습자료 및 검증자료는 모두 동일하게 하였다. 또한 인공신경망 학습에 사용된 목표함수(비용함수)는 모두 SSE를 사용하였으며, 학습중지를 위한 임계치 0.01, 학습률 0.01, 은닉층의 활성화함수는 로지스틱함수, 출력층 활성화함수는 선형함수로 동일하게 적용하였다. 마지막으로 최적화의 알고리즘은 전통적인 ‘back-propagation’에 비해 효율성이 개선된 ‘resilient backpropagation with weight backtracking’을 동일하게 적용하였다. 실제 각 대안별 망구조 및 학습 기준의 식별에는 여러 가능성을 검토하기 위해 임계치, 학습률, 최적화 알고리즘 등을 다양하게 시도하였으나 이러한 학습 기준의 변화에 대해 최종 결과치의 민감도가 매우 낮아 이하에 설명된 결과들은 위에서 제시한 동일한 기준에 의해 학습된 결과만을 대상으로 하였다.

보인 만큼, 본 연구는 인공신경망모형 자체에 집중하여 인공신경망모형 내에서 대안적 조기경보지수 도출방안을 비교 분석하여 가장 성과가 우수한 대안을 식별하고자 한다. 다만, 인공신경망 모형을 이용한 본연구의 최종 결과를 국제곡물 분야에서 여타 모형을 적용한 김종진·김지연(2016)의 연구 결과와 비교함으로써 인공신경망모형의 우수성을 보이고자 한다.

²³ 양승룡 외(2014)의 연구는 위기지수를 직접 예측하여 이를 조기경보지수로 사용하는 방법에 비해 각 곡물의 가격을 예측하고 이를 조기경보지수로 재구성하는 방법이 더 우수한 예측력을 보인다는 것을 보였다.

최적 망구조 식별은 다음의 순서를 따랐다. 우선 은닉층 수 1개, 은닉층 노드 1개의 가장 단순한 망구조를 설정한 후 학습자료와 위에 열거된 기준을 바탕으로 학습을 수행한다. 인공신경망의 학습 결과와 검증자료를 이용하여 검증구간 내에서의 출력변수에 대한 예측치를 생성하여 조기경보지수를 계산한다. 단, 조기경보지수는 인공신경망 학습과정에서 각 노드의 연결강도를 나타내는 가중치의 초기 값(initial value)이 난수 생성을 통해 임의로 선택되어 동일한 조건으로 학습된 예측 값에도 얼마간의 차이가 발생할 수 있다. 따라서 실제 비교 시에는 동일 조건의 학습을 100회 수행하고 각각의 학습 결과로 예측치를 생성한 후 이를 평균하는 방법으로 초기 값 임의선택으로 인한 예측치의 변동성을 완화하였다. 이후 계산된 조기경보지수와 실측 위기지수를 이용하여 RMSPE를 계산한다. 최적 망구조의 식별은 은닉층 수와 각 층의 노드 수를 점차적으로 증가시킨 망구조에 대해 각각 위에 설명한 방법에 의해 RMSPE를 계산한 결과를 서로 비교하여 가장 우수한 예측력, 즉 예측치의 오차율이 가장 작은 망구조를 최종 망구조로 선택하였다.

표 2. 인공신경망 망구조 식별: (㉠, ㉡)안의 경우(예)

은닉층 수	노드 수	RMSPE		
		검증자료	학습자료	전체자료
1	1	9.36	7.83	8.16
	2	8.74	5.64	6.44
	3	9.30	3.57	5.25
	4	9.29	2.86	4.87
	5	9.50	2.55	4.80
	6	9.65	2.32	4.76
	7	9.79	2.04	4.71
	8	9.66	1.90	4.62
	9	10.44	1.74	4.89
	10	10.97	1.64	5.08
2	1×1	10.01	7.79	8.28
	2×2	8.59	6.13	6.78
	3×3	9.80	4.05	5.73
	1×2	9.67	7.81	8.21
	2×1	8.48	7.40	7.66
	2×3	8.79	5.69	6.49
	8×6	10.45	1.97	4.96


주 1) 은닉층 활성화함수=logistic, 출력층 활성화함수=선형, 목표함수=SSE, 알고리즘=resilient back propagation with weight backtracking, 학습률=0.01을 사용한 결과임. 실제 계산은 R의 'neuralnet' 패키지 사용하며 계산함.

2) 각 망구조의 RMSPE 값은 동일한 망구조와 학습 기준으로 100회의 반복 학습을 수행한 결과의 평균값이며 가중치의 최적화 과정에서 초기 가중치를 임의로 선택함에 따라 매 수행 결과에 조금씩 차이가 발생함.

<표 2>는 위에서 설명된 (a), (2)안에 의한 인공신경망모형의 최적 망구조 식별을 위해 계산된 망구조별 RMSPE를 보여주고 있다. 이 표에는 최적 망구조 식별의 기준이 되는 검증자료에서 뿐만 아니라 학습자료와 전체자료(학습자료와 검증자료를 통합한 자료)에 대해서도 각각 RMSPE를 계산한 결과를 보여주고 있다. 우선, 은닉층 수를 고정시킨 상태에서 노드 수를 증가시킬 경우 학습자료에서의 적합도를 나타내는 RMSPE는 노드 수가 증가함에 따라 감소하는 패턴을 보인다. 이는 망구조를 복잡하게 할수록 학습자료에서의 적합도를 높일 수 있음을 의미한다. 그러나 검증자료에서의 RMSPE는 2번째 노드까지 감소하는 형태를 보이다 이후 노드 수가 증감함에 따라 증가하는 것을 볼 수 있다. 이는 인공신경망모형의 과적합(over-fitting)문제를 나타내는 것으로 적정 망구조 선택의 중요성을 보여주는 것이라 할 수 있다. <표 2>에서 최적 망구조로 식별된 것은 2개의 은닉층과 (2×1)개의 노드를 갖는 구조로 이때 검증자료에서의 RMSPE는 8.48%로 계산되었다.

<그림 3>은 (a), (2)의 대안에 대해 최종 식별된 망구조로 학습된 가중치들의 결과를 보여준다. 입력, 은닉 및 출력층의 노드와 각 노드들의 연결강도를 나타내는 가중치가 표시된 결과를 볼 수 있다.

그림 3. 최종 식별된 인공신경망 학습결과: (a), (2)안의 경우(예)



주: 임계치=0.01, 은닉층 활성화함수=logistic, 출력층 활성화함수=선형, 목표함수 =SSE, 알고리즘=resilient backpropagation with weight backtracking, 학습률=0.01 및 학습 자료를 이용한 결과로 100회의 반복학습 중에서 가장 뛰어난 성과를 보인 결과임. 실제 계산은 R의 ‘neuralnet’ 패키지를 사용하여 계산함.

5. 조기경보지수 산출

아래 <표 3>은 위에서 설명한 방법과 식별 기준으로 제시된 여섯 가지 대안에 대해 각각 최적 망구조를 식별하고 식별된 최적 망구조하에서 계산된 RMSPE를 보여주고 있다.²⁴ 우선 학습자료에서의 RMSPE는 위기지수의 구성요소 통합 정도, 즉 ㉠, ㉡, ㉢안 간의 차이는 크지 않은 것으로 계산되었다. 물론, ㉢안의 경우 여타 안에 비해 RMSPE가 다소 큰 것을 볼 수 있으나 유의미한 차이를 나타내는 것은 아닌 것으로 보인다. 그러나 3개월 선행시점만을 출력변수로 사용하는 경우(㉠안)와 1~3개월 모두를 출력변수로 사용하는 경우(㉡안)에는 큰 차이가 발생하는 것을 볼 수 있다. ㉠안의 경우는 1개의 출력노드(y_{t+3})에 대해서만 오차(SSE)를 최소화하도록 학습하여 1~3개월의 모든 경우($y_{t+1}, y_{t+2}, y_{t+3}$)를 고려하는 경우보다 학습자료에서 예측오차를 크게 줄일 수 있었던 것으로 보인다.

표 3. 대안별 최적 망구조의 성과 비교

대안		최적 망구조	RMSPE		
			검증자료	학습자료	전체자료
㉠	①	9	9.46%	1.26%	4.34%
	②	2×1	8.48%	7.40%	7.66%
㉡	①	8	9.24%	1.38%	4.27%
	②	2×1	7.95%	7.42%	7.55%
㉢	①	6×5	8.21%	1.72%	3.96%
	②	1	7.18%	7.40%	7.36%

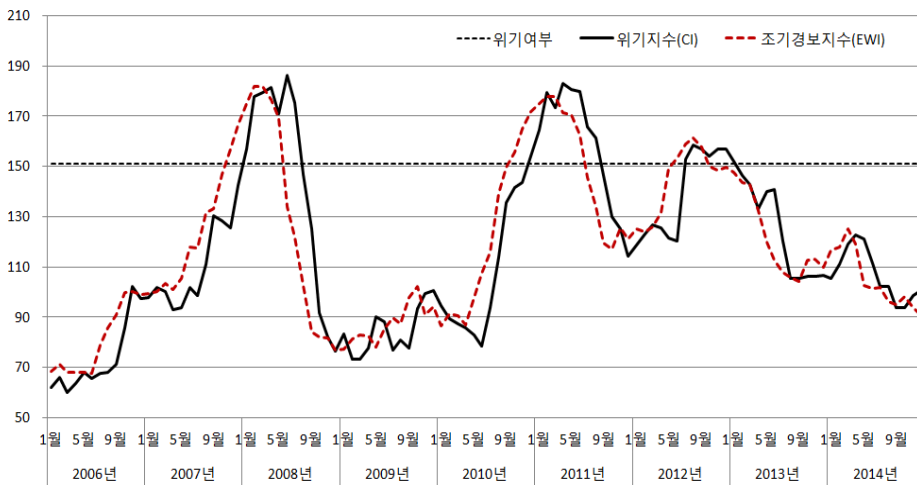
주: 대안 ㉠은 개별 곡물가격($P_{i,t+3}$) 예측하여 위기지수를 재구성, ㉡는 국제곡물 가격지수(P_{t+3})를 예측하여 위기지수를 재구성, ㉢은 위기지수(C_{t+3})를 직접 예측을 의미하며 ①은 3개월 선행 시점(y_{t+3})만을 출력층 노드로 설정, ②는 1~3개월 선행시점($y_{t+1}, y_{t+2}, y_{t+3}$) 모두를 출력층 노드로 추가하는 안을 의미함. 최적 망구조는 검증자료의 RMSPE를 기준으로 식별함.

최적 망 식별기준으로 사용된 검증자료에서 계산된 RMSPE 결과는 다음의 두 가지 경향성을 나타낸다. 첫째, 출력 노드에 사용된 변수의 통합 정도가 클수록 예측치의 정확도가 커지는 것으로 나타난다. 즉, ㉠, ㉡, ㉢안들에 대해 ㉡안이 ㉠안에 비해 예측 오차가 작게 나타나며 ㉢안이 ㉡안에 비해 예측오차가 작게 나타났다. 이러한 경향성

²⁴ 위에서 설명한 (㉠, ㉡)안에 대한 망식별 과정을 나머지 다섯 가지 안에 대해서 동일하게 수행하였으나 관련 내용은 생략하였다.

은 1~2개월 선행시점을 출력 노드에 포함하였는가의 여부(①, ②안 여부)와 상관없이 나타났다. 출력변수의 통합 정도가 클수록 검증자료에서의 예측오차가 줄어드는 것은 인공신경망모형 내에서 각 곡물가격을 이용해 조기경보지수를 계산하는 방법을 학습하여 예측에 사용하였기 때문일 것으로 유추된다. 둘째, 3개월 선행 변수만 출력 노드에 두는 안(① 안)에 비해 1-3개월 모두를 출력노드에 포함시킬 경우(② 안)의 예측성도가 좋게 계산되었으며 그 차이는 예측오차 1% 남짓이었다. 2안의 RMSPE는 학습자료에서 계산된 것과 비교해도 큰 차이가 발생하지 않으며 특히, (㉔, ㉕) 안의 경우 학습자료보다 검증자료에서 계산된 RMSPE가 더 작은 값을 보여주었다. 이상의 결과를 요약하면 출력 노드 값의 집계 정도가 클수록 그리고 모든 중간 예측치를 출력 노드에 포함할 경우가 검증자료에서의 예측력이 높다는 것이다.

그림 4. 조기경보지수와 위기지수 추이



주: (㉔, ㉕)의 안과 최적 망구조(은닉층 수 =1, 은닉층 노드 수=1)로 전체 자료에 대해 학습한 결과를 바탕으로 조기경보지수를 계산함. 조기경보지수(EWI)는 100회 반복계산의 평균값을 이용하여 계산함.

<그림 4>는 가장 우수한 안으로 식별된 (㉔, ㉕)안으로 작성된 표본기간 내의 조기경보지수와 실제 위기지수의 추이를 보여주는 그림이다. 전반적으로 조기경보지수가 위기지수를 선행하여 움직이며 위기지수의 예측력이 매우 높은 것을 볼 수 있다. 조기경보지수의 위기 예측력을 보면, 2008년 1월부터 시작된 위기의 경우 조기경보지수는 위기 발생 시점보다 2개월 빠른 시점인 2007년 11월에 155.0으로 나타나 위기 발생 기준인 151.1을 상회하였다. 또한 2010년 12월부터 발생한 위기는 이보다 3개월 빠른 2010년 9월 조기경보지수가 이미 150.7에 달해 3개월 이전에 위기를 예측한 것으로 볼 수 있다.

마지막으로 2012년 7월 위기는 위기발생 1개월 전인 6월(152.3)에 위기 발생이 예측되었다. 이상의 결과는 본 연구에서 제안된 인공지능경망모형을 통한 조기경보지수가 2~3개월 선행시점에서 위기발생 여부를 비교적 잘 예측하는 것을 보여준다.

김종진·김지연(2016)의 연구는 국내 경제·사회 분야에 구축된 조기경보시스템에서 가장 많이 사용하고 있는 회귀분석모형, 프로빗모형 및 신호접근모형을 이용하여 국제곡물 시장의 조기경보지수를 각각 작성하고 이들의 성과를 비교하였다. <표 4>는 인공지능경망모형을 이용한 본 연구 결과의 우수성을 보이기 위해 김종진·김지연(2016)에서 성과비교 지표로 사용한 Kaminsky 확률과 프로빗모형 확률의 RMSE(Root Mean Squared Error) 및 MAE(Mean Absolute Error)와 N/S비율(Noise-Signal Ratio)을 본 연구에서 최적으로 제시된 ①, ②안을 이용하여 계산한 결과를 보여주고 있다.²⁵ 모든 비교지표에서 인공지능경망 모형을 이용한 본 연구 결과가 뚜렷이 개선된 것을 확인할 수 있다.

표 4. 선행연구와 본 연구 결과의 비교

구 분		Kaminsky 확률		프로빗모형 확률		N/S비율
		RMSE	MAE	RMSE	MAE	
김종진·김지연 (2016)	회귀분석모형	0.221	0.097	0.254	0.167	0.048
	프로빗모형	0.225	0.101	0.251	0.154	0.031
	신호접근모형	0.263	0.138	0.283	0.194	0.067
본 연구(인공지능경망 모형)		0.205	0.084	0.211	0.107	0.015

주: 각 비교지표의 의미 및 작성방법은 김종진 외(2014), 김종진·김지연(2016) 등을 참고 바람.

자료: 김종진 김지연(2016: 52) 재구성.

6. 결론

본 연구는 국제곡물 부문의 조기경보시스템 구축을 위한 조기경보모형으로 인공지능경망모형을 제안하였으며 인공지능경망모형을 이용하여 조기경보지수를 도출하는 다양한 방안을 검토하였다. 예측력이 우수한 조기경보지수를 도출하기 위해 인공지능경망의 출력층 노드의 수를 다양하게 하거나 조기경보지수의 집계 정도를 달리하여 그 결과를 비교 분석하였다. 이러한 분석 결과를 바탕으로 출력층에 가능한 한 통합된 지수를 사

²⁵ 각 비교지표의 의미 및 작성방법은 김종진·김지연(2016: 50-52)을 참조하기 바람.

용하고 필요한 예측시점 이전의 시점에 대한 예측도 함께 수행하도록 하는 망구조가 가장 우수한 예측력을 보여준다는 것을 밝혔다. 또한 이렇게 식별된 망구조로 실제 조기경보지수를 계산한 결과를 위기지수 및 선행연구 결과와 비교하여 본 연구에서 제안한 방법으로 계산된 조기경보지수의 예측력이 매우 뛰어남을 보였다.

인공신경망모형은 패턴 인식능력이 뛰어나 특히 단기 예측에 우수한 성능을 발휘하는 반면, 변수들 간의 장기적인 균형관계에 바탕을 둔 경제학적 이론에 근거하지 않기 때문에 중장기적인 예측에 취약하다. 또한 인공신경망의 노드를 잇는 가중치 및 은닉층이 복잡하게 얽혀있는 형태로 예측 값에 대한 설명변수들의 기여정도를 알 수 없다는 한계를 가진다. 결과 값에 대한 원인 규명이 불가능하다는 것은 차후 발생 가능한 위기의 원인에 대한 설명 없이 예측 결과만을 제시할 수 있다는 의미로, 대응정책 수립시의 활용 가능성이라는 측면에서 한계점을 갖게 될 뿐만 아니라 사회적 합의를 통한 대응책 마련이라는 측면에서도 어려움을 줄 것으로 예상된다. 따라서 본고에서 제시된 인공신경망모형에 의한 국제곡물 부문의 조기경보지수는, 신호접근모형과 같이 기존 모형에 의한 지수를 대체하기보다는 이와 함께 보완적으로 사용되어 각각의 단점을 서로 보완할 수 있도록 운영하는 것이 타당하다고 본다. 즉, 보다 정확한 예측을 위해서는 인공신경망모형에 의존하고 이러한 예측치를 보이게 되는 원인에 대한 설명은 신호접근모형 등의 여타 모형을 이용하는 등의 방안을 생각할 수 있을 것이다.

조기경보시스템을 구축하기 위해서는 조기경보지수 산출을 위한 조기경보모형에 더하여 해당 분야를 주기적으로 모니터링하고 관련 분야의 뉴스와 전문가 의견 등의 정성적 자료를 분석해야 한다. 그리고 이를 정량적 정보라 할 수 있는 조기경보지수와 함께 종합적으로 해석하여 최종적인 위기단계를 판단해주는 구체적인 조직과 전문 인력이 필요하다. 뿐만 아니라 환율, 유가 등도 곡물의 수입단가에 영향을 주어 사료 및 식품물가에 영향을 크게 줄 수 있으나 국제곡물 조기경보시스템에서 이러한 분야를 모두 고려하기에는 너무 많은 비용이 소요될 수 있으므로 이미 구축되어 운영되고 있는 여타 분야의 조기경보시스템과 통합적으로 운영될 필요가 있을 것으로 보인다.

본 연구는 국제곡물 분야 조기경보지수의 예측력 증대라는 주제에 한정하여 진행된 것으로 실제 국제곡물 분야의 조기경보시스템을 구축하기 위해서는 다음과 같은 후속 연구 및 작업이 필요하다. 첫째, 해당 분야에 대한 주기적인 모니터링을 통해 필요한 정보를 축적할 수 있는 인적·물적 자원을 갖추어야 한다. 둘째, 신호접근모형과 같은 기존 모형과 본고에서 제안한 인공신경망모형의 장점을 적절히 결합할 수 있는 조기경보모형 통합 방안이 마련되어야 한다. 셋째, 전문가 의견 등의 정성적 자료의 체계적 반영 방안이 필요하다. 이를 위해서는 전문가 자문그룹을 두어 이들 의견을 적극 반영

하는 방안을 생각할 수 있다. 넷째, 환율, 석유 등 기존에 구축되어 운영 중인 여타 조기경보시스템과의 통합적인 정보망을 구축하여야 한다. 마지막으로 위기정보 단계별 대응 방안에 관한 매뉴얼을 작성하여 위기가 예측될 경우 즉각적인 선제적 대응이 이루어질 수 있도록 하여야 할 것이다.

참고 문헌

- 강용진. 2010. “주가의 불안정성 지수를 활용한 조기경보시스템 구축.” 석사학위 논문.
- 김종진, 김지연, 공민지, 최선우, 이동주, 채주호. 2014. 「국제곡물 조기경보시스템 구축」. 한국농촌경제연구원.
- 김종진, 김지연. 2016. “국제곡물시장 조기경보모형에 대한 개선연구.” 「농촌경제」 제39권 제1호.
- 김태훈, 승준호. 2009. “신호접근법을 이용한 국제곡물가격 조기경보시스템.” 「농촌경제」 제32권 제3호.
- 서하나. 2009. “여신사후관리를 위한 조기경보모형개발 및 성능평가.” 석사학위 논문.
- 양승룡. 2014. 「인공 신경망을 이용한 국제곡물 조기경보시스템 개발」. 고려대학교 산학협력단. 한국농촌경제연구원 위탁연구보고서.
- 윤덕룡, 송원호, 김권식, 이형근, 배희연. 2004. 「석유위기 조기경보 시스템 개발」. 대외경제정책연구원.
- A. Anastasiadis, G. Magoulas, and M. Vrahatis. 2005. “New globally convergent training scheme based on the resilient propagation algorithm.” *Neurocomputing*. vol. 64, pp. 253-270.
- Kim, Dong Ha, Suk Jun Lee, Kyong Joo Oh and Tae Yoon Kim. 2009. “An early warning system for financial crisis using a stock market instability index.” *The Journal of Knowledge Engineering*. vol. 26, no. 3.
- McNelis, Paul D. 2005. *Neural Networks in Finance: Gaining Predictive Edge in the Market*. Elsevier Academic Press.
- Oh, Kyong Joo, Tae Yoon Kim and Chiho Kim. 2006. “An early warning system for detection of financial crisis using financial market volatility.” *The Journal of Knowledge Engineering*. vol. 23, no. 2.
- Riedmiller M. 1994. “Description and Implementation Details.” Technical Report. University of Karlsruhe.
- Riedmiller M. and Braun H. 1993. “A direct adaptive method for faster backpropagation learning: The RPROP algorithm.” Proceedings of the IEEE International Conference on Neural Networks(ICNN), pages 586-591. San Francisco.
- Song, Wonho. 2010. “Building an Early Warning System for Crude Oil Price Using Neural Network.” *Journal of East Asian Economic Integration*. vol. 14, no. 2, December 2010.

원고 접수일: 2016년 1월 25일
원고 심사일: 2016년 2월 5일
심사 완료일: 2016년 6월 1일