

딥러닝 분석을 이용한 중국 역내·외 위안화 변동성 예측

이우식¹ · 전희주²

¹안양대학교 정보통계학과 · ²동덕여자대학교 정보통계학과
접수 2016년 2월 11일, 수정 2016년 2월 28일, 게재확정 2016년 3월 3일

요약

2008년 글로벌 금융위기 이후 중국은 위안화 국제화의 점진적 추진을 진행하면서 중국상하이 외 환시장과 중국홍콩 외환시장에서 거래되는 통화인 역내위안화와 역외위안화를 형성시켰다. 본 연구는 위안화 국제화와 점진적인 중국 자본계정 개방에 따라 급변하는 외환시장상황의 변동성을 정확하게 파악하기 위해서 GARCH모형 (일반화된 자기회귀 조건부이분산성모형)에 다단계인공신경망을 결합한 MLP-GARCH 모형과 GARCH모형과 기계학습의 일종인 딥러닝 (deep learning)을 통합한 DL-GARCH를 가지고 위안화 변동성예측을 비교 실험과 분석을 하였다. 비교분석 결과 DL-GARCH 모형은 MLP-GARCH보다 모형 위안화 역내·외 환율변동성 예측 면에서 더욱 더 개선된 예측값을 제공하였다. 그래서 이분산시계열모형을 딥러닝과 결합한 DL-GARCH 모형은 시계열의 환율 변동성 예측 문제에 딥러닝을 응용할 수 있음을 확인하였다. 향후 이분산시계열과 결합된 딥러닝 모형은 다른 금융시계열 데이터에 응용하여 그 일반화 가능성을 높일 수 있을 것이다.

주요용어: 딥러닝, 위안화, 인공신경망, 환율 변동성 예측, DL-GARCH, GARCH모형.

1. 서론

2008년 국제 금융위기 이후 중국은 위안화를 국제 결제통화로 육성하기 위해 중국 상하이 국제금융시장에 역외 거래가 불가능한 역내위안화와 중국 홍콩 국제금융시장에 역외 거래가 가능한 역외위안화로 분리하였다. 이런 분리 정책은 아시아 및 비아시아 국가에도 역외 위안화 시장이 활성화될 수 있는 영향력을 미치며 중국 위안화의 영역을 넓혀가고 있다.

홍콩에서는 홍콩 내의 위안화 영업규제 해제 (2010년 2월)로 홍콩의 위안화 예금액은 급증하여 2014년 5월말 기준 예금액이 9,558억 위안을 기록하였고, 홍콩 내의 위안화 수급에 따라 결정되는 자유화된 역외 위안화 환율이 적용되고 있다. 홍콩 외에도 국제은행간통신협회 (society of worldwide interbank financial telecommunication; SWIFT)의 보고서인 "RMB Monthly Tracker"에 따르면 런던, 싱가포르, 대만, 독일, 영국, 미국 그리고 호주 등도 역외위안화시장으로 급성장하고 있다. 최근 위안화를 외환준비통화로 편입시키는 국가가 증가하고 있으며 국제통화기금 (IMF)은 특별인출권 (special drawing rights) 구성통화로 위안화를 편입하였다.

우리나라에서는 한-중 정상회담 (2014년 7월 3일) 이후 위안화적격 외국인기관투자자 자격을 얻어 대한민국 원 (KRW)과 중국 위안화 직거래시장이 개설되었다 (2014년 12월 1일). 이 후 중국 자본시장에 직접 투자할 수 있는 경로가 형성되어 우리나라의 위안화 허브 육성도 본격화 되었지만 역외 위안화에 대한 연구들은 많이 이뤄지지 않고 있는 상태이다 (Lee와 Chun, 2015).

¹ (14028) 경기도 안양시 만안구 삼덕로 37번길 22, 안양대학교 정보통계학과, 외래교수.

² 교신저자: (02748) 서울시 성북구 화랑로 13길, 동덕여자대학교 정보통계학과, 부교수.

E-mail: hjchun@dongduk.ac.kr

최근 중국 위안화 분석에 대한 선행연구로 Lee와 Chun (2015)의 중국 역내·외 위안화 현물시장간의 상호 연계성 연구가 있다. 하지만 중국 외환시장 환경이 급변하게 변화함에 따라 시장 변수들은 많은 잡음 (noise)을 갖게 되었으며 중국 위안화환율의 리스크, 즉 중국 위안화 변동성을 예측하기 위해 고려해야 할 정성적, 정량적 변수들이 점차로 증가하고 있는 현실 속에서 시계열모형 자체는 예측함수를 구성하는 변수의 분포에 대한 엄격한 가정을 요구하고 있다. 이 때문에 시계열모형은 시장 변수들을 모형 속에 직접 반영하기가 어렵고, 계량적 변수와 정성적 변수가 혼합된 경우 성과가 좋지 못하다는 단점이 있다 (Blurn와 Langley, 1997; Roh 등, 2005; Kim 등, 2008). 인공지능경망을 결합한 환율변동성예측은 이와 같은 시계열 모형의 단점을 극복하기 위한 좋은 대안이 될 수 있다.

기존 변동성 예측 연구 중 인공지능경망의 적용 가능성을 제시한 Weigend와 Shi (1998)는 유전자 알고리즘모형과 GARCH (1,1) 모형을 비교하여 인공지능경망모형이 주가지수 변동성을 좀 더 정확히 예측함을 보였으며, Brooks (1998)은 기존 변동성모형과 인공지능경망모형을 개별주식의 변동성 예측에 사용하여 더 나은 예측성적을 보였다. Roh (2013)는 코스피200 주가지수의 변동성을 추정하기 위해 인공지능경망모형과 통합한 모형을 제시하였다. 본 연구는 기존의 인공지능경망모형의 한 단계 발전된 기계학습의 일종인 딥러닝을 이용하여 중국위안화 환율변동성 예측을 하고 기존인공지능경망모형과 비교 평가하고자 한다.

2. 이론적 배경 및 연구방법

2.1. 이론적 배경

2.1.1. 인공지능경망

인공지능경망 모델은 층, 연결강도, 전이 함수, 학습 알고리즘 등으로 이루어진 데이터처리 시스템이라고 할 수 있다. 대부분의 인공지능경망 모형에는 입력층, 은닉층 그리고 출력층으로 구성되어 있고 각 층마다 처리단위인 뉴런을 가지고 있다.

입력층에서는 외부로부터 입력 자료를 받아들여 이를 데이터처리 시스템으로 전송한다. 시스템 내에 존재하고 있는 은닉층은 입력 값을 넘겨받아 처리한 뒤, 출력층으로 보낸다. 입력자료를 토대로 판별모형과 같이 각 입력변수들의 상대적 가중치가 인식패턴의 결과로 기억되고 이 결과들의 처리가 모형의 마지막 결과가 되는 것이다. 즉 인공지능경망의 구조는 서로 다른 층에 존재하는 뉴런의 가중치로 서로 연결되어 있다.

이렇게 각 층 사이의 뉴런과 뉴런사이에 상호 연결강도는 인공지능경망이 인식한 패턴을 결정한다. 즉 인공지능경망의 구조는 서로 다른 층에 존재하는 뉴런이 서로 연결되어 있다. 각 처리단위는 연결되어 있는 타 처리단위로부터 입력을 받아 입력함수를 통해 가중합을 하여 순입력 값을 구한다. 이 때 해당 처리단위의 출력 값은 전이함수를 이용하여 순입력 값의 합계를 구한다. 이렇게 구한 인공지능경망이 결정한 변동성과 실제 변동성 값을 비교하여 차이를 줄여나가는 방법으로 연결강도를 조절하면서 실제 값에 수렴하도록 하게 된다. 이것을 학습 알고리즘이라고 한다.

인공지능경망의 학습 알고리즘은 결정한 변동성 값과 실제 변동성 값을 비교하여 차이를 줄여나가는 방법으로 연결강도를 조절된 실제 값에 수렴하도록 한다. 학습 알고리즘은 주어진 문제에 대한 연결강도의 값을 찾는 절차이다. 역전파 알고리즘은 인공지능경망 학습 알고리즘들 중 하나로 다음과 같은 과정을 거친다. 입력층의 각 뉴런에 학습 대상 패턴이 입력되면 이 신호는 각 은닉층에서 종합되어 전이함수를 거쳐 출력층에 전달된다. 출력층에 전달된 값은 은닉층에서와 같은 절차를 통해 출력 값으로 산출되어 이를 실제 값과 비교하게 된다. 출력 값과 실제 값을 비교하여 그 차이를 최소화하기 위해 역으로 다시 각 처리요소와 연결되어 있는 뉴런의 연결강도를 조정하고 다시 순방향으로의 계산과 역방향으로 연결

강도 조정을 계속하여 모든 패턴의 값에 만족하도록 오차를 줄여나가는 방향으로 학습하여 예측하는 알고리즘이다.

인공신경망 모형은 그 자체의 블랙박스적 특성 때문에 입력 변수와 출력변수와의 상호 관계를 이해하기 쉽지 않고 최적의 은닉층 및 은닉뉴런의 수를 결정지어 주는 이론적 토대가 없는 결점에도 불구하고 인공신경망 모형은 금융 분야의 연구에 활용되어왔다.

2.1.2. 딥러닝

기존의 인공신경망 경우 자료에 대한 표현 능력을 크게 증가시키기 위해 은닉층이 한 개 있는 신경망에 은닉뉴런수를 증가시키거나, 한 두 개의 은닉층을 추가하여 다단계신경망을 사용하였다. 이는 입력층에서 출력층으로 가는 통로의 개수를 세는 것으로 설명할 수 있다. 즉 은닉뉴런 혹은 은닉층이 많을수록 입력층과 출력층 사이를 더 많은 방법으로 모델링 할 수 있다는 것을 의미한다 (Choi와 Min, 2015).

하지만 여러 은닉뉴런 또는 여러 은닉층이 포함된 다단계신경망에서 신경망을 학습하는데 사용되는 역전파 알고리즘이 예러 정보를 출력층에서 입력층 방향으로 전달되면서 점점 사라진다는 문제가 발생한다. 이는 학습 정도가 초기의 랜덤 값에서 크게 벗어나지 못하고 은닉층이 한 개 있는 신경망과 비슷한 학습효과를 나타내기 때문이다. 이에 2006년 Hinton교수가 사전학습이 포함된 딥러닝을 제시하였다. 딥러닝의 경우 다단계신경망과 달리 마지막 은닉층까지 충분히 전파가 가능하여 (Hinton와 Salakhutdinov, 2006; Schmidhuber, 2015) 현재 페이팔 (PayPal)을 포함한 핀테크업체들은 딥러닝 분석을 적용하고 있다.

기존 다단계신경망은 단지 무향 그래프로 구성된 반면, 딥러닝은 기존 다단계신경망과 같은 네트워크 구조이지만 무향 그래프와 유향 그래프로 구성된다. 즉 무향 그래프에서 사전학습을 시킨 후, 유향 그래프에서 미세조정 하는 방법이다. 더불어 기존 다단계신경망은 각각의 연상층으로 데이터를 연산 및 전달해가며 값을 출력해내는 비확률적 모델인 반면, 딥러닝은 데이터를 생성하는데 초점이 맞추어 있는 모델로 주어진 데이터에 대해 다른 뉴런들의 상태가 확률로 존재하는 확률모델이다. 이에 본 연구에서는 기존 다단계신경망과 딥러닝의 성능평가를 위해 C++를 사용 두 개의 모델을 비교하고자 한다.

2.2. 연구 모형

본 연구는 중국 역내·외 위안화 현물환율의 변동성을 분석하기 위해 대표적인 모수적모형인 일반화된 자기회귀 조건부이분산성모형 (generalized autoregressive conditional heteroscedasticity; GARCH)과 비모수적방법인 인공신경망 모형을 결합함으로써 환율 변동성의 예측을 하고자 한다.

2.2.1. 일반화된 자기회귀 조건부 이분산성 모형

환율 수익률의 분산은 시간에 따라 변화하는데, 이는 수익률의 변동성은 과거의 정보가 미래 수익률에 영향을 주는 조건부이분산을 해야 한다는 것을 의미한다. 변동성을 갖는 시계열을 조건부분산의 관점에서 모형화하기 위해 Engle (1982)은 p 차 자기회귀형 조건부분산 모형 (autoregressive conditional heteroscedasticity; ARCH)을 제안하였다. 그러나 금융 시계열들의 변동성 추정 시 자료의 지속성으로 ARCH 모형의 조건부분산 함수에 시차 (p)가 길어져 부등식 제약조건에서 많은 모수를 추정해야 한다. 그래서 Bollerslev (1982)는 작은 모수를 추정해도 지속적 변동성을 충분히 고려할 수 있는 GARCH 모형을 제안했다. GARCH (p, q)에 의한 조건부분산 모형은 다음과 같다.

$$\sigma_t^2 = \omega + \sum_{i=1}^p \alpha_i \epsilon_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2$$

본 연구에서는 자산 기대수익률과 변동성의 추정에 대표적으로 적용되는 GARCH (1, 1)모형을 사용했으며 이에 대한 모형은 아래와 같다 (Song과 Ko, 2013; Kang, 2009).

$$\begin{aligned} y_t &= \sigma_t z_t, \quad z_t \sim N(0, 1) \\ \sigma_t^2 &= \omega + \alpha_1 \epsilon_{t-1}^2 + \beta_1 \sigma_{t-1}^2 \\ \epsilon_t &= \sigma_t \zeta_t, \quad \zeta_t | \zeta_{t-1} \sim N(0, \sigma_t^2) \end{aligned}$$

2.2.2. 통합인공신경망 모델의 개발

인공신경망을 이용하여 t 시점의 변동성을 예측하는데 있어 GARCH모형을 이용하여 조건부적인 연관성을 갖고 있는 두 개의 변수 ϵ_{t-i}^2 와 σ_{t-j}^2 를 사용할 수 있으며 두 개의 변수들은 각각 α_i 와 β_j 에 의해 조정된 후 인공신경망의 입력 변수로서 다단계인공신경망모형 (ML-GARCH)과 딥러닝모형 (DP-GARCH)에 입력변수로 사용된다.

반복적 시행착오를 거치지 않고 단순히 이전시점의 변동성만을 그대로 입력변수로 대입한 인공신경망 모형의 경우 모델의 예측력을 개선하기 위해 입력변수의 조정계수, 즉 σ_{t-j}^2 의 가중치를 선정하기 위해 경우의 수에 따라 수많은 시행착오를 거쳐 모형을 완성하게 된다. 하지만 MLP-GARCH모형의 경우 이미 GARCH모형을 이용하여 통계적으로 가중치를 선정하고 이러한 가중치에 의해 조정된 σ_{t-j}^2 를 입력변수로 대입하여 학습하기 때문에 학습과정에 있어서 효율성의 증대를 가져오게 된다. 더불어 ϵ_{t-i}^2 을 입력변수로 대입함으로써 예측력을 향상시킬 수 있다 (Roh, 2013). 조건부 변동성의 세 가지 변수들은 다음과 같다.

ω : 비 조건부 변동성 상수

ϵ_{t-i}^2 : ($t-i$) 시점 (최근시점)의 잔차 (residual)

σ_{t-j}^2 : ($t-j$) 시점 (최근시점)의 변동성 제곱

다단계인공신경망에는 탄력적 역전과 학습방법을 이용하였고, 딥러닝에는 쌓아 올린 오토인코더 학습 방법을 이용한다. 주성분분석과 같이 오토인코더는 데이터의 특징을 추출할 수 있는 방법으로 입력층의 뉴런수와 출력층의 뉴런수를 같게 하고, 입력과 출력이 같은 값이 되도록 신경망을 학습시킨다. 신경망의 학습 능력을 향상시키기 위하여 오토인코더를 쌓아 올릴 수 있다. 쌓아 올린 오토인코더는 딥러닝의 무향 그래프에서 사전학습을 시킨 후, 미리 학습된 결과를 초기 추측으로 사용하여 유향 그래프에서 쌓아 올린 오토인코더를 미세조정을 통해 학습을 시킨다.

3. 실증분석

본 연구에서 사용할 표본기간은 중국 역외 위안화 환율이 2010년 8월 23일에 처음 시행된 시점부터 2015년 8월 6일까지 중국 역내·외 위안화 현물환율 현물환율에 대한 일별 데이터이며 이는 블룸버그 (Bloomberg)에서 수집했다.

Table 3.1에서 중국 역내·외 위안화 현물환율의 수익률에 대한 평균, 표준편차, 왜도 및 첨도에 대한 기초통계량을 제시하였다.

$$\text{역내위안화환율 (CNY/USD) 변화율} = \ln(\text{현물환율}(t)/\text{현물환율}(t-1))$$

$$\text{역외위안화환율 (CNH/USD) 변화율} = \ln(\text{현물환율}(t)/\text{현물환율}(t-1))$$

Table 3.1 Statistic summary

	CNY	CNY Return	CNH	CNH Return
mean	6.295	0.000	6.291	0.000
median	6.237	0.000	6.235	0.000
max.	6.811	0.006	6.785	0.013
min.	6.041	-0.006	6.020	-0.009
s.d.	0.171	0.001	0.165	0.002
skewness	0.953	0.032	0.780	0.991
kurtosis	0.208	4.023	-0.089	11.623




Figure 3.1 Time series of CNY and CNH

중국 역내·외 위안화 현물환율 수익률의 안정성을 검정하기 위해 확장된 Dickey-Fuller (ADF)의 단위근 검정을 이용하여 분석하였다. 이에 대한 결과는 Table 3.2에 제시되었다.

Table 3.2 The ADF unit root test

CNY	CNY Return	CNH	CNH Return
-2.271 (0.464)	-10.162 (0.010)	-2.410(0.405)	-10.445 (0.010)

단위근 검정결과 (Table 3.2), CNY와 CNH 시계열의 확장된 ADF 검정통계량 추정값은 -2.271과 -2.409이며 p -value 수치는 각각 0.464과 0.405이다. 따라서 통계적 5% 유의수준에서 각 시계열에 단위근이 존재한다는 귀무가설을 기각할 수 없기 때문에 CNY와 CNH 시계열은 비정상성이라고 할 수 있다. 그러나 단위근 검정결과 CNY변화율과 CNH변화율 시계열의 확장된 ADF 검정통계량 추정값은 -10.162과 -10.445이며 p -value 수치는 각각 0.01과 0.01이다. 따라서 5% 유의수준에서 각 시계열에 단위근이 존재한다는 귀무가설을 기각할 수 있기 때문에 CNY변화율과 CNH변화율에 대한 시계열은 정상적이라고 할 수 있다. 따라서 중국 역내·외 위안화 현물환율의 변화율 시계열자료에 어떠한 정상성을 위한 변환도 실시하지 않고 바로 모형추정을 하였다.

수집된 위안화 수익률 자료로 추정된 모형의 잔차들이 시간에 따라 변동과 안정 상태를 반복하는 것으로 나타나서 본 연구에서는 중국 역내·외 위안화 현물환율 수익률의 변동성을 적절하게 잘 설명할 수 있는 GARCH 모형을 사용하여 자료를 추정하였다.

우선 ARCH LM (lagrange multiplier) 검정결과로 ARCH 효과를 살펴보면 (Table 3.3), 시차 2, 5, 10에서 $p < 0.05$ 으로 유의미하게 중국 역내·외 위안화 현물환율 수익률에 명확한 ARCH 효과가 존재함을 알 수 있다. 이런 경우 오차항의 시차변수 p 뿐 아니라 조건부분산의 시차변수 q 까지 고려하는 GARCH 모형이 필요하므로, 자료 분석 시 이를 적용하였다.

Table 3.3 ARCH LM tests

lag	CNY	CNY Return	CNH	CNH Return
	Chi-square (p-value)	Chi-square (p-value)	Chi-square (p-value)	Chi-square(p-value)
2	68.775 (1.11E-15)	81.426 (2.2e-16)	135.702 (2.20E-16)	164.583 (2.20E-16)
5	74.487 (1.19E-14)	85.732 (2.2e-16)	144.940 (2.20E-16)	176.545 (2.20E-16)
10	79.449 (6.44E-13)	91.335 (2.887e-15)	155.526 (2.20E-16)	188.817 (2.20E-16)

GARCH 모형에 의한 분석 결과 (Table 3.4)를 보면, GARCH 모형의 제약조건인 α 와 β 의 합이 각각 0.996와 0.996으로 1보다 작으면서 1에 매우 가까운 근사값을 가진다. 따라서 이는 변동성 충격 (volatility shocks)에 매우 지속적 (persistent)이라는 것을 의미한다. 역내·외 위안화를 비교해 볼 때, 역외 위안화가 장기평균으로 회귀하는 속도가 더 빠르다.

Table 3.4 Estimation results of GARCH (1,1) model

	CNY Return				CNH Return			
	estimate	s.e.	t	p-value	estimate	s.e.	t	p-value
μ	0.000	0.000	-3.132	0.002	0.000	0.000	-1.909	0.0562
ω	0.000	0.000	2.088	0.037	0.000	0.000	2.938	0.003
α	0.198	0.035	5.662	0.000	0.128	0.020	6.263	0.000
β	0.815	0.030	27.017	0.000	0.862	0.021	41.281	0.000

Table 3.4에 의한 GARCH (1,1)의 결과는 다음과 같다.

$$\begin{aligned} \sigma_t^2 &= 0.198\epsilon_{t-1}^2 + 0.815\sigma_{t-1}^2 \\ \sigma_t^2 &= 0.128\epsilon_{t-1}^2 + 0.862\sigma_{t-1}^2 \end{aligned}$$

본 연구에서는 인공지능망학습을 결합한 모형은 MLP-GARCH과 딥러닝을 통합한 DL-GARCH 모형은 다음과 같이 모두 GARCH(1,1)에서 계산한 계수를 사용한다 (Table 3.5).

역내위안화:

$$\begin{aligned} \sigma_t^2 &= 0.198\epsilon_{t-1}^2 + 0.815\sigma_{t-1}^2 \\ \epsilon_{t-1}^2 &= 0.198\epsilon_{t-1}^2 \\ \sigma_{t-1}^2 &= 0.815\sigma_{t-1}^2 \end{aligned}$$

역외위안화:

$$\begin{aligned} \sigma_t^2 &= 0.128\epsilon_{t-1}^2 + 0.862\sigma_{t-1}^2 \\ \epsilon_{t-1}^2 &= 0.128\epsilon_{t-1}^2 \\ \sigma_{t-1}^2 &= 0.862\sigma_{t-1}^2 \end{aligned}$$

Table 3.5 Summary of inputs in models

Asset	Model	Input
CNY	MLP-GARCH	0.198 ϵ_{t-1}^2
	DL-GARCH	0.815 σ_{t-1}^2
CNH	MLP-GARCH	0.128 ϵ_{t-1}^2
	DL-GARCH	0.862 σ_{t-1}^2

인공신경망모형에 의한 변동성 예측은 다음 방법을 사용하였다. 자료를 두 부분으로 나누는 방법으로 훈련자료의 80%를 통하여 모형을 훈련시키고 나머지 20%에서 검증하여 최종적으로 모형을 선택하였다. 평가의 정확도를 높이기 위해 10겹 교차 검증을 1회 반복하였다. 즉 데이터를 훈련 데이터와 검증 데이터로 나누어 모델링 및 평가하는 작업을 10회 반복하였다. 그리고 교차 검증을 통해 최선의 모델(Table 3.6)을 가지고 실험자료에 적용해 성능을 평가하였다.

Table 3.6 Optimal artificial network models

Optimal Network	MLP-GARCH		DL-GARCH	
	CNY	CNH	CNY	CNH
Hidden Layer1	2-4-1	2-4-1	2-5-1	2-4-1
Hidden Layer2	2-4-2-1	2-1-1-1	2-1-4-1	2-1-5-1
Hidden Layer3	2-4-2-4-1	2-3-5-1-1	2-4-4-4-1	2-1-5-4-1

본 실험에 사용한 인공신경망 모형은 2개의 입력뉴런과 1개의 출력뉴런 그리고 1~3개까지의 은닉층 개수의 변화와 1~5개의 은닉뉴런수의 변화를 주었다. 더불어 다단계인공신경망에는 탄력적 역전과 학습방법을 이용하였고, 딥러닝에는 쌓아 올린 오토인코더 학습방법을 이용하였다 (Table 3.7).

시계열분석에서 예측은 예측오차가 작을수록 예측이 정확하게 이루어졌다고 볼 수 있다. 예측의 정도를 평가하는 척도는 평균제곱오차 (MSE), 제곱근 평균제곱오차 (RMSE), 평균 절대퍼센트오차 (MAPE) 그리고 평균절대오차 (MAE) 등이 있을 수 있으나, 일반적으로 제곱근 평균제곱오차를 흔히 사용한다. Table 3.7은 전체표본을 이용하여 추정한 결과 다단계인공신경망의 경우 은닉층의 수를 늘려 학습효과를 높이려고 했지만 테스트자료에서 보는바와 같이 은닉층이 많을수록 오차가 커짐을 알 수 있었다. 이는 입력층에 가까운 은닉층까지 역전파가 충분히 도달하지 못했고 이는 학습효과를 떨어뜨리게 하였다. 즉, 깊은 은닉층이 경우 출력층에 가까운 은닉층만으로도 학습이 이루어질 수 있다는 문제가 있다. 이와 반대로 립러닝의 경우 은닉층이 많을수록 오차가 줄어들어 학습효과를 높임을 알 수 있었다.

Table 3.7 RMSE of the training and testing

RMSE		MLP-GARCH		DL-GARCH	
		CNY	CNH	CNY	CNH
Training	Hidden Layer1	0.00000581	0.00000638	0.00000371	0.00000349
	Hidden Layer2	0.00000506	0.00000495	0.00000372	0.00000354
	Hidden Layer3	0.00000487	0.00000457	0.00000369	0.00000348
Testing	Hidden Layer1	0.00000474	0.00000285	0.00000136	0.00000106
	Hidden Layer2	0.00000829	0.00000374	0.00000007	0.00000022
	Hidden Layer3	0.00000686	0.00000710	0.00000040	0.00000023

본 논문이 제안한 딥러닝을 이용한 중국위안화 변동성예측의 성능을 평가하기 위해 다단계 인공신경망과 딥러닝의 비교실험을 수행하였고 그 결과는 Table 3.7과 같이 딥러닝모형 결과가 우월하였다.

4. 결론 및 시사점

2008년 국제 금융위기 이후 중국은 위안화를 국제 결제통화로 육성하기 위해 중국 상하이 국제금융시장에 역외 거래가 불가능한 역내위안화와 중국 홍콩 국제금융시장에 역외 거래가 가능한 역외위안화로 분리하였다. 이런 분리 정책은 아시아 및 비아시아 국가에도 역외 위안화 시장이 활성화될 수 있는 영향력을 미치며 중국 위안화의 영역을 넓혀가고 있다.

본 연구는 딥러닝 기법을 GARCH에 결합한 새로운 DL-GARCH 기법을 제안하였고 위안화 국제화와 중국 외환시장 규제 완화에 따라 급변하는 외환시장상황의 변동성을 정확하게 파악하기 위해 2010년

8월 23일부터 2015년 8월 6일까지 역내·외 위안화 환율의 변동성 예측에 대해 GARCH모형에 다단계 인공신경망과 결합한 MLP-GARCH 모형과 비교 분석을 하였다. 그 결과 DL-GARCH 모형은 MLP-GARCH보다 모형 위안화 역내·외 환율변동성 예측 면에서 더욱 더 개선된 예측값을 제공하였다. 이는 이분산시계열모형에 기계학습의 하나인 딥러닝을 결합한 모형이 환율 변동성 예측 문제에 응용될 수 있음을 확인하였다. 향후 본 연구에서 제안된 이분산시계열모형과 딥러닝을 결합한 DL-GARCH기법은 다른 금융시계열 데이터에 응용할 수 있는 일반화 가능성을 보여준다.

References

- Blurn, A. and Langrey, P. (1997). Selection of relevant features and examples in machine learning. *Artificial Intelligence*, **97**, 245-271.
- Bollerslev, T. (1982). Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, **31**, 307-327.
- Brooks, C. (1998). Predicting stock index volatility: Can market volume help? *Journal of Forecasting*, **17**, 59-80.
- Choi, H. and Min, Y. (2015). Introduction to deep learning. *Korea Information Processing Society Review*, **22**, 7-21.
- Engle, R. F. (1982). Autoregressive conditional heteroscedasticity with estimates of variance of United Kingdom inflation. *Econometrica* **50**, 987-1008.
- Hinton, G. and Salakhutdinov, R. (2006). Reducing the dimensionality of data with neural networks. *Science*, **313**, 504-507.
- Kang, I. (2009). An empirical study on efficient forecasting method of Korea and Asian emerging stock market's volatility. *Korean Journal of Financial Engineering*, **8**, 25-46.
- Kim, K., Cho, M. and Park, E. (2008). Forecasting the volatility of KOSPI 200 using data mining, *Journal of the Korean Data & Information Science Society*, **19**, 1305-1325.
- Lee, W. and Chun, H. (2015). A study on the relationship between the onshore and offshore Chinese Yuan markets, *Journal of the Korean Data & Information Science Society*, **26**, 1387-1395.
- Roh, T. H., Lee, T. and Han, I. (2005). Forecasting the volatility of KOSPI 200 using neural network-financial time series model. *Korean Management Review*, **34**, 683-713.
- Roh, T. H. (2013). Integration model of econometric time series for volatility forecasting. *Korean Management Consulting Review*, **13**, 313-340.
- Schmidhuber, J. (2015). Deep learning in neural networks : An overview. *Neural Networks*, **61**, 85-117.
- Song, J. and Ko, B. (2013). Testing the exchange rate data for the parameter change based on ARMA-GARCH model. *Journal of the Korean Data & Information Science Society*, **24**, 1551-1559.
- SWIFT Watch Standard Chartered, RMB services, <https://www.sc.com/en/banking-services/renminbi/>.
- Weigend, A. S. and Shi, S. (1998). *Predicting daily probability distributions of S&P 500 returns*, Information Systems Working Papers Series-98-23, Stern School of Business, New York University, New York.

A deep learning analysis of the Chinese Yuan's volatility in the onshore and offshore markets

Woosik Lee¹ · Heuiju Chun²

¹Department of Information Statistics, Anyang University

²Department of Statistics & Information Science, Dongduk Women's University

Received 11 February 2016, revised 28 February 2016, accepted 3 March 2016

Abstract

The People's Republic of China has vigorously been pursuing the internationalization of the Chinese Yuan or Renminbi after the financial crisis of 2008. In this view, an abrupt increase of use of the Chinese Yuan in the onshore and offshore markets are important milestones to be one of important currencies. One of the most frequently used methods to forecast volatility is GARCH model. Since a prediction error of the GARCH model has been reported quite high, a lot of efforts have been made to improve forecasting capability of the GARCH model. In this paper, we have proposed MLP-GARCH and a DL-GARCH by employing Artificial Neural Network to the GARCH. In an application to forecasting Chinese Yuan volatility, we have successfully shown their overall outperformance in forecasting over the GARCH.

Keywords: Deep learning, DL-GARCH, GARCH, The Chinese Yuan, volatility.

¹ Adjunct faculty, Department of Information Statistics, Anyang University, Gyeonggi-do 14028, Korea.

² Corresponding author: Associate professor, Department of Statistics & Information Science, Dongduk Women's University, Seoul 02748, Korea. Email: hjchun@dongduk.ac.kr