CNN-LSTM Neural Network Model for Quantitative Strategy Analysis in Stock Markets

S a L [1], C a Z a [2], a d J e Ma[1](✉)

[1] Department of Information Science, School of Mathematical Sciences and LMAM, Peking University, Beijing 100871, China
jwma@math.pku.edu.cn

[2] Academy for Advanced Interdisciplinary Studies, Peking University, Beijing 100871, China

Abstract. In this paper, the convolutional neural network and long short-term memory (CNN-LSTM) neural network model is proposed to analyse the quantitative strategy in stock markets. Methodically, the CNN-LSTM neural network is used to make the quantitative stock selection strategy for judging stock trends by using the CNN, and then make the quantitative timing strategy for improving the profits by using the LSTM. It is demonstrated by the experiments that the CNN-LSTM

[5]. T e ca e CNN f c a e ac e e e a a e c e ec a e .

T ac e e be e e , e ad e ec e e a e (RNN) c a e ed e f e e f de f ce e e a da a. L S -Te Me (LSTM) e f e cce f RNN a c ec e e a ad e b e e a e [6]. LSTM d ce e e ce , a f c a a e ace ad a a - ca e e dde a e f e e . W e e e ce , e a e ab e effec e a ca e e e a d e e e, e ce a e c e f c da a d a ca e e ed c ca ac [7]. He ce e ca e LSTM ac e e e a a e a e .

T e e e e a e a CNN-LSTM e a e de ca d e a e f ca da a e , a d e c e d a - a e e ec a d a e a d a d ab e. T e e f a e a ed a f . I Sec . 2, e e a b ef e e f e CNN a d LSTM, e de c be e CNN-LSTM f a e . Sec 3 e e e CNN-LSTM c a , a d e e e e a e f a e a e c a f e ba c M e a e a d Be c a de . F a , e c c de e a e a d e e f e Sec . 4.

2 CNN-LSTM Neural Network

2.1 CNN

F e ed c a ca , CNN a e cce f de a d e e a e- f- e-a e a be c a [8]. Ac a , e a e c ec ed e . A f f e a a ea ed e a c ec- e, a d e de ee f a a a a ce ded a a ca . T a c a d f e a e a e ea e , a da a-d e fa , a a ea e ac fea e de c b e . T e f CNN f a e a d f a de a ca be ee e e a e [9].

CNN a e e a c ca de e c a a e a e a e b-

2.2 LSTM

Rec e e a e e ca ab d a ca c a e a e e e ce d e e a ec e ce [11]. RNN ca ec e d a c e e f e e a a ca , e a e c a a e e f a feed-f a d e , a d e a ab e a a e b a ed f c a c e e e ed c [12,13]. O e f RNN de - - e e c e e e a de a , a d e a a e f a d f e e c c e ca be ab e a d ed. T e ea ce f RNN de e e e e a e a e e beca e e e a ec e e a c ec e [14].

A c e a c f e a a LSTM b c [15] ca be ee F . 1. I fea e ee a e (, f e a d), b c , a e ce (e C a E Ca e), a ac a f c , a d ee e c ec . T e f e b c ec e c ec ed bac e b c a d a f e a e . T e ec f a f LSTM a e f a d a a e e [15]. I de fac a e de a d , ed be :

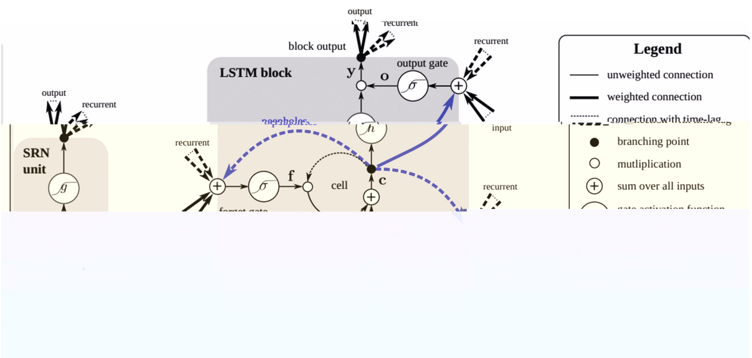

Fig. 1. Detailed Long Short-Term Memory block as used in the hidden layers of a recurrent neural network.

$$z^t = g(W_z x^t + R_z y^{t-1} + b_z) \qquad \textit{block input} \qquad (2)$$

$$i^t = \sigma(W_i x^t + R_i y^{t-1} + p_i \odot c^{t-1} + b_i) \qquad \textit{input gate} \qquad (3)$$

$$f^t = \sigma(W_f x^t + R_f y^{t-1} + p_f \odot c^{t-1} + b_f) \qquad \textit{forget gate} \qquad (4)$$

$$c^t = i^t \odot z^t + f^t \odot c^{t-1} \qquad \textit{cell state} \qquad (5)$$

$$o^t = \sigma(W_o x^t + R_o y^{t-1} + p_o \odot c^t + b_o) \qquad \textit{output gate} \qquad (6)$$

$$y^t = o^t \odot h(c^t) \qquad \textit{block output} \qquad (7)$$

e e x^t e ec a e t, e W a e e a ce , e R a e a e ec e e a ce , e p a e ee e e ec a d

b a e b a ec . F c σ, g a d h a e - e - ea ac a f c : *logistic sigmoid* $\left(\frac{1}{1+e^{-x}}\right)$ ed f a ac a f c f e a e a d e b c a e ed a e b c a d ac a f c . T e - e ca f ec de ed a $\odot$. T e c e d Bac -P a a T T e(BPTT) f a ca be f d [15] e e a a e a .

2.3 CNN-LSTM F a

T a ac d ead a b a a decea e a e a e a ca a e ad a a e f a a e a a e da a- e e (ce e -ba c e) a e a a e e a e e . A e a e , a e a - f a d a ac d be e a e c a e eac , b da e e LSTM e f e e de e e c a e e c e ca a .

T e de a f CNN-LSTM c a a d a a e e a e de c bed e F . 2 a d e Tab e 1 a f :

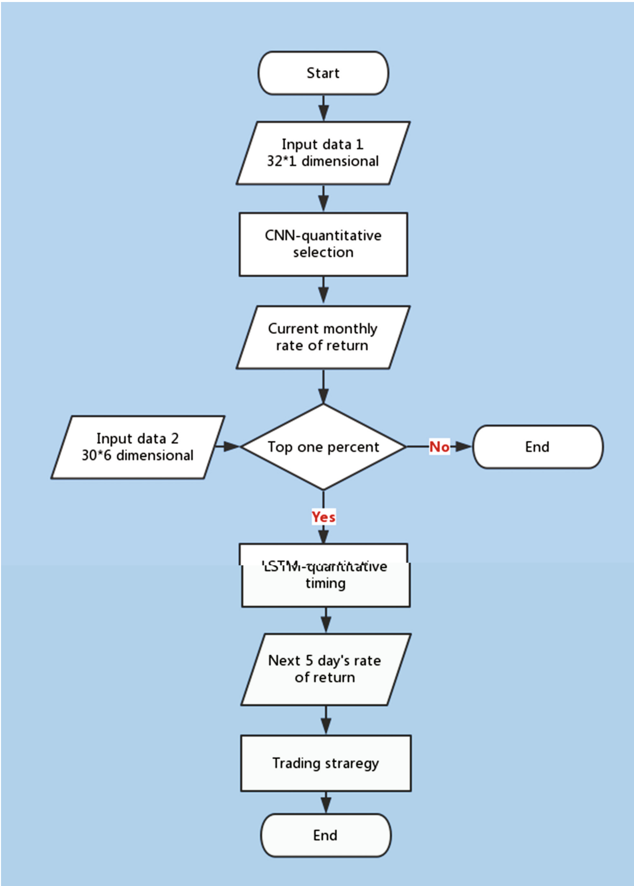

Fig. 2. CNN-LSTM flow chart.

We b a da a d d a C e e c f e SINA FINANCE eb. T e a e c e e e d f 2007-1-1 2013-12-31, a d e e e c e e e d f 2014-1-1 2017-3-31. Da a e a d e ce f CNN-LSTM e a e a e de c bed e f a e .

Table 1. The parameters for CNN-LSTM.

Parameters	CNN	LSTM
Input layer	1	1
Conv/LSTM hidden layer	2	1
FCN hidden Layer	2	1
Output layer	1	1
Epoch	500	100
Activation	ReLU, Tanh	Tanh
Weight	Normal(0,1)	Normal(0,1)
Optimizer	Adam	Adam
Learning rate	0.001	0.001
Objective function	Cross-entropy	Cross-entropy

We d d - c e a da d a f da a e ece a [16]. F e e t, e e e 12 a e f e f $t-13$ $t-2$ a d e 20 da a e f e a e f CNN a a e e ec e, a d bef e 30 da fea e : [e , c e , , , a , e] a f LSTM a a e e . O e fea e c a e be fed e e a e a e c e a d a ed f ed c a a d b a e a d e . I CNN-LSTM de , e LSTM a c ed f a e e a a e f ed b 1 LSTM a e a d de e a e Ta ac a . O e f e a e e f e d ffic a d a e a e . O e ea a e de e f e a da a, b f e e da a e ed c effec . T e ea a e da a a d e a ead c ca ed de . T a d e - f e de , e d ec a added e CNN-LSTM de a d e e a a e a ed e e . D efe d e fea e a d e e b e f e de . Re a a efe add a L2 e ca c a f e f c , a e f e e a e c e 0 a d f ced ada a f eac fea e. T e e e b e , a e e effec f fea e c ce.

W e e LSTM ed c e a e e a 1, e b a d d 5 da , a d f e , da e e be f e d da a 5 a d c e e d. W e e LSTM ed c e a e e a -1, c e f , a d f a ead e d a e , e be f e d da be dec ea ed b e, a d f e be f e d da e a 0, e e e a e. F e 3 e a f CNN-LSTM de e e da a e . T e a be ee c ec e ea a e a e e a a e c e ec a e f eac b e CNN, e a f a e f b e. Mea e, e e e a a e a 1 bef e e e d f e de a e a e LSTM ec a a e e a a e a e effec e .

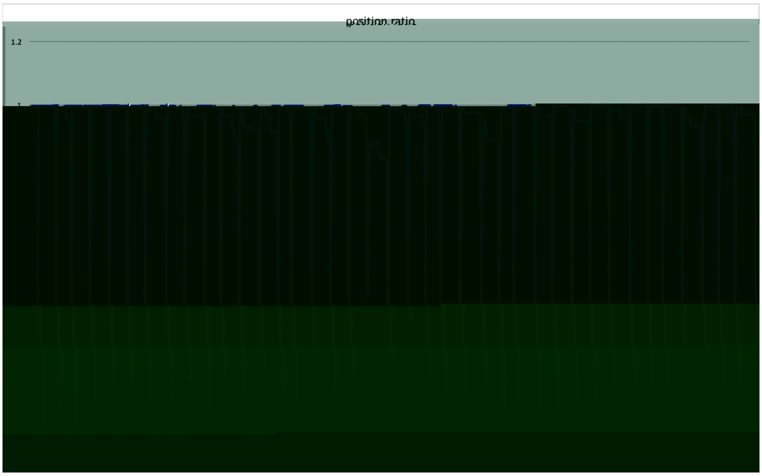

Fig. 3. The position ratios of CNN-LSTM model in the test dataset.

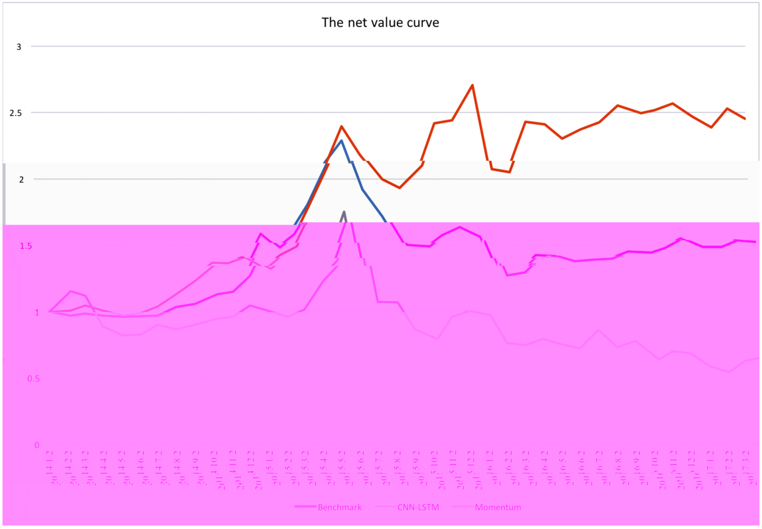

Fig. 4. The net value curves of Benchmark, CNN-LSTM and Momentum.

Table 2. The comparison of the results

	Benchmark	CNN-LSTM	Momentum
Annualized rate of return	0.136	0.309	−0.118
Maximum retracement	0.443	0.241	0.689

We c a e e a a ed a e f e , e a e ace e a d e e a e f CNN-LSTM de e ba c M e a e a d Be c a de e ec e e Tab e 2 a d F . 4. Ba c e a e e e ca d a c a e e 3- -12 (e) c e e f e e e e fe e a e c a e (e). T e e a e c e de a e a ca c ea e e e f a ce a a e . D e c a e c a , e a e ace e f CNN-LSTM e ab e. T e a a ed a e f e CNN-LSTM e a e de e a 2 e a a e a e a a ed a e f e Be c a de . Mea e, e a e ace e f CNN-LSTM e a e de e ec e 34%, 54% f e a e ace e f e ba c M e a e a d Be c a de . T e e e e f a e de effic e a d e e e e e , a d e f e b e a d ac cab f e a a e .

4 Conclusion and Future Work

We a e a ed e dee ea c ad a d ade a c - b e a ed ac e ea e a e. F , e a CNN ca e ac ef fea e e e f a - - e e e e da a c a a c a a e ce f e a e a a e e ce ed. A d e a e e a a e c e ec a e f d c e d b e CNN. Sec d, e e LSTM e a e ed c a acc ac f e c ce a d e ed c c e a e ed a a , c ca e e e ace e f e CNN c e ec de e bac e a e. O de ea acc da e e f d ffe e f e e - ce e a e a e da a a d d ce e e e a e ceed e ba c M e a e a d Be c a de e a a ce e a e. We a e cce f a ed e CNN-LSTM e a e de a d a e a a e c e ec a d a e c fea b e, b a d ab e.

T e e f f e ed c c a a c e a d c ea - c a eed, a e d ca be a ed e da a ead f e da da a. F e e, f e a e de ac a e e dec , e eed e e e a ec , c a fea e e ec- , de c c a d a a e e a .

Acknowledgement. This work was supported by the Natural Science Foundation of China for Grant 61171138.

References

1. Fu, C., Fu, M., Que, J.: Prediction of stock price base on radial basic function neural networks. Technol. Dev. Enterp. **4**, 005 (2004)
2. Sun, W., Guo, J., Xia, B.: Discussion about stock prediction theory based on RBF neural network. Heilongjiang Sci. Technol. Inf. **22**, 130 (2010)
3. Liu, S., Ma, J.: Stock price prediction through the mixture of gaussian processes via the precise Hard-cut EM algorithm. In: Huang, D.-S., Han, K., Hussain, A. (eds.) ICIC 2016. LNCS, vol. 9773, pp. 282–293. Springer, Cham (2016). doi:10.1007/978-3-319-42297-8_27
4. Chavarnakul, T., Enke, D.: Intelligent technical analysis based equivolume charting for stock trading using neural networks. Expert Syst. Appl. **34**(2), 1004–1017 (2008)
5. Ding, X., Zhang, Y., Liu, T., Duan, J.: Deep learning for event-driven stock prediction. In: International Conference on Artificial Intelligence, pp. 2327–2333. AAAI Press (2015)