



Prediction of compressive strength of self-compacting concrete containing different fillers with the help of Artificial Neural Networks

S. M. Masrouri Saadat, E. Jahani*

Faculty of Engineering, Mazandaran University, Babolsar, Iran

Review History:

Received: Aug. 29, 2021

Revised: Jan. 22, 2022

Accepted: Feb. 20, 2022

Available Online: Jun. 08, 2022

Keywords:

Self-compacting concrete

Compressive strength prediction

ANN neural network

LSTM neural network

ABSTRACT: Self-compacting concretes with suitable rheological and mechanical properties, are among the new concretes that were considered by researchers and industrialists in the late 20th and early 21st centuries. Accuracy in pouring concrete, concrete density and also the appearance of concrete as an exposed material is always a concern of designers and executors of construction projects. Self-compacting concrete with weight compression properties can always be one of the options available to designers. The variety of materials used in self-compacting concrete, including recycled materials, with pozzolanic properties and fillers to achieve rheological and mechanical goals, is one of the challenges that designers face. Also, accurate determination of mixing ratios and their results are very time-consuming and costly. Using soft computing and neural networks inspired by the biological structure of the human brain, computer science seeks to increase speed, accuracy, and cost reduction to prevent malicious experiments. In this study, with the help of ANN and LSTM networks, using 320 samples of self-compacting concrete with dispersion and comprehensiveness of common materials used in it by various researchers, tried to predict the 28-day compressive strength of self-compacting concrete, evaluate performance and increase accuracy by 6. The training algorithm is different. In total, about 200 repetitions of training were performed on 320 samples of self-compacting concrete with 14 characteristics, which by comparing the best results obtained from training algorithms, best performance with root mean square error of 4.97 and correlation coefficient of 0.9484 in the test, for the network. ANN was reported with the Bayesian Regularization training algorithm, which indicates the high accuracy of that network.

1- Introduction

Concepts and architectural complexities of new structures, if considered as basic materials, face challenges, which are related to the efficiency and psychologicality of concrete while maintaining its strength and durability. Self-compacting concrete to address the concerns of designers and business owners, such as: The difficulty of concreting in high volumes and compacting it, as well as the use of concrete as a final and visible material in construction projects, was first developed by Okamura in the late 1980s to achieve sustainable structures in Japan[1]. Later, in 2002, the European Institute EFNARC published a guide to self-compacting concrete in order to maintain coherence in the design process of this type of concrete[2]. In order to achieve the optimal mixing ratios in order to achieve the desired results in the tests of self-compacting concrete in the fresh and hardened state according to the relevant standards by changing each of the parameters including aggregate (sand), water to cement ratio (W / P), superplasticizers, etc., perform trial and error and perform destructive tests such as compressive strength test of concrete. Given the quality and performance of self-

compacting concretes and a large number of additives and alternatives to cement in this type of concretes, researchers are looking for a solution to prevent wastage of time and energy and also to achieve high-reliability results based on previous experience [3]. Computer science and neural networks allow us to establish relationships between variables and outputs by creating nonlinear functions that are not traditionally possible to formulate. The aim of this study was to predict the 28-day compressive strength of self-compacting concrete with a focus on the study of fillers and viscosity and psychological modifiers using ANN and LSTM neural networks with the nature of post-diffusion learning and deep learning.

2- Description of neural networks

2- 1- ANN Network

ANN with MLP structure or multilayer perceptron layers is a feed-forward artificial neural network with a Backpropagation training method. This method is based on reducing the gradient or derivative in each step. In general, the network has three parts: input layer, hidden layer and

*Corresponding author's email: e.jahani@umz.ac.ir



output layer. The function of the network is that the samples are entered with any number of features from the input part, and after receiving random weights in the first iteration, it enters the hidden layer and the activation function and deviation value are applied to it, and then it goes to the output

$$\sum_{j=1}^m w_{ij} x_j + b_j \tag{1}$$

$$\frac{1}{1+e^{-x}} \text{ or } \frac{e^x - e^{-x}}{e^x + e^{-x}} \text{ and ...} \tag{2}$$

$$w_i = w_j(t) + 2\eta(t_p - f_p) \tag{3}$$

. Gradient activation function . x_{ij}

2- 2- LSTM Network

LSTM or short-term stable memory is a recursive neural network, meaning that the network outputs re-enter the network as input in the next iteration. Lstm was first introduced by Hochreiter in the early 1990s and expanded by Hochreiter and Schmidhuber in the late 1990s [4]. Using it, the problem of zeroing and infinity of derivative networks, the so-called networking, was somehow solved. The Lstm output consists of two parameters, which represent the network memory and the target output, respectively, both of which are entered and entered into the network in the next step. So unlike our feed network, it has an RNN network, which is used in deep learning.

$$f_t = \sigma_g (W_f x_t + U_f h_{t-1} + b_f) \tag{4}$$

$$i_t = \sigma_g (W_i x_t + U_i h_{t-1} + b_i) \tag{5}$$

$$o_t = \sigma_g (W_o x_t + U_o h_{t-1} + b_o) \tag{6}$$

$$\tilde{c}_t = \sigma_c (W_c x_t + U_c h_{t-1} + b_c) \tag{7}$$

$$c_t = f_t \circ c_{t-1} + i_t \circ \tilde{c}_t \tag{8}$$

$$h_t = o_t \circ \sigma_h (c_t) \tag{9}$$

3- Results and Discussion

Now if we want to compare the best state of the LSTM network with the ANN network according to the path we did in this particular case, the performance of Bayesian Regularization training algorithm in the ANN network will be better than Sgdm algorithm in LSTM network only according to RMSE index. Was. It should also be noted that this does not mean denying the LSTM network and other training algorithms, and only in this particular case this result is achieved (Table 1, Figure 1).

Table 1. Comparison of ANN and LSTM network performance

Neural network	Training Algorithm	RMSE
		Test
ANN	Bayesian Regularization	4.9700
LSTM	Sgdm	7.1850




Fig. 1. Error Diagrams and Correlation Coefficient of ANN Network Considering Bayesian Regularization Algorithm

4- Conclusion

Although the results of ANN network with Bayesian Regularization training algorithm are better than the other two training algorithms in this network (Levenberg Marquardt and Scaled Conjugate Gradient), this does not mean that the other two training algorithms can not perform prediction, Rather, the accuracy of the prediction during training is less with the other two training algorithms, which even in this particular issue, there was little difference.

Neural network training with Bayesian Regularization training algorithm takes more time than the other two training algorithms, and the more data and features of each input, the training time to correct the weights increases, on the other hand, Scaled Conjugate Gradient training algorithm spends less time and consequently It is also less accurate.

References

- [1] H. Okamura, M. Ouchi, Self-compacting concrete– Journal of Advanced Concrete Technology, vol. 1. (2003).
- [2] EFNARC, Guidelines for Self-Compacting Concrete, European Federation for Specialist Construction Chemicals and Concrete Systems, Norfolk, UK. English ed., February, (2002).
- [3] A. Iqtidar, N. Bahadurkhan, S. Kashif-ur-Rehman, M. Faisal Javed, F. Aslam, R. Alyousef, H. Alabduljabbar, A. Mosavi, Prediction of compressive strength of rice husk ash concrete through different machine learning processes. Crystals, 11(4) (2021) 352.
- [4] S. Hochreiter, J. Schmidhuber, Long short-term memory. Neural computation, 9(8) (1997) 1735-1780.

HOW TO CITE THIS ARTICLE

S. M. Masrouri Saadat, E. Jahani, Prediction of compressive strength of self-compacting concrete containing different fillers with the help of Artificial Neural Networks, Amirkabir J. Civil Eng., 54(10) (2023) 779-782.

DOI: 10.22060/ceej.2022.20488.7438





پیش‌بینی مقاومت فشاری بتن خودتراکم حاوی فیلرهای مختلف با کمک شبکه‌های عصبی مصنوعی

سید معین مسروری سعادت، احسان جهانی*

دانشکده فنی مهندسی، دانشگاه مازندران، بابلسر، ایران

تاریخچه داوری:

دریافت: ۱۴۰۰/۰۶/۰۷
بازنگری: ۱۴۰۰/۱۱/۰۲
پذیرش: ۱۴۰۰/۱۲/۰۱
ارائه آنلاین: ۱۴۰۱/۰۳/۱۸

کلمات کلیدی:

بتن خودتراکم
پیش‌بینی مقاومت فشاری
شبکه عصبی ANN
شبکه عصبی LSTM

خلاصه: بتن‌های خودتراکم با خواص رئولوژی و مکانیکی مناسب، از بتن‌های جدید محسوب می‌شوند که در اواخر قرن ۲۰ و اوایل قرن ۲۱ مورد توجه محققین و صاحبان صنایع قرار گرفت. دقت در بتن‌ریزی، تراکم بتن و همچنین ظاهر بتن به عنوان یک متریکال اکسپوز همواره از دغدغه‌های طراحان و مجریان پروژه‌های عمرانی محسوب می‌شود. بتن‌های خودتراکم با خاصیت تراکم وزنی همواره می‌تواند از گزینه‌های پیش روی طراحان باشد. تنوع در مواد مورد استفاده در بتن‌های خودتراکم از جمله مواد بازیافتی، با خاصیت پوزولانی و پرکنندگی در جهت رسیدن به اهداف رئولوژی و مکانیکی، از چالش‌هایی است که طراحان با آن روبرو هستند. همچنین دقت در تعیین نسبت‌های اختلاط و نتایج حاصل از آن بسیار زمان بر و پرهزینه می‌باشد. علوم کامپیوتر با بهره‌گیری از محاسبات نرم و شبکه‌های عصبی الهام گرفته از ساختار بیولوژیکی مغز انسان، سعی در افزایش سرعت، دقت و همچنین کاهش هزینه به جهت جلوگیری از آزمایشات مخرب می‌پردازد. در این پژوهش با کمک دو شبکه ANN و LSTM با بهره‌گیری از ۳۲۰ نمونه بتن خودتراکم با پراکنندگی و جامعیت مصالح رایج مورد استفاده در آن توسط محققین مختلف، سعی در پیش‌بینی مقاومت فشاری ۲۸ روزه بتن خودتراکم، بررسی عملکرد و افزایش دقت توسط ۶ الگوریتم آموزشی مختلف شده است. در مجموع حدوداً ۲۰۰ تکرار آموزش بر روی ۳۲۰ نمونه بتن خودتراکم با ۱۴ ویژگی انجام شد، که با مقایسه بهترین نتایج حاصل از الگوریتم‌های آموزشی، بهترین عملکرد با ریشه میانگین مربعات خطای ۴/۹۷ و ضریب همبستگی ۰/۹۴۸۴ در آزمایش، برای شبکه ANN با الگوریتم آموزشی Bayesian Regularization گزارش شد، که نشان دهنده دقت بالای آن شبکه می‌باشد.

۱- مقدمه

محققین به جهت دستیابی به نسبت‌های بهینه اختلاط در راستای رسیدن به نتایج مطلوب در آزمایشات بتن‌های خودتراکم در حالت تازه و سخت شده طبق استانداردهای مربوطه با تغییر هر کدام از پارامترها اعم از سنگدانه (شن و ماسه)، نسبت آب به مواد سیمانی (W/P)، فوق روان کننده‌ها و ...، اقدام به آزمون و خطا و انجام آزمایشات مخرب از قبیل آزمایش مقاومت فشاری بتن می‌نمایند. میکائیل فابین گراناتا، با حفظ ساختار اصلی بتن خودتراکم و افزودن میکروسیلیس^۱، پودر پومیس^۲، افزودنی کاهنده آب^۳ و اصلاح کننده لزجت^۴، اذعان داشت پومیس علاوه بر خاصیت پرکنندگی، خاصیت پوزولانی مطلوبی داشته به نحوی که این ویژگی تاثیر قابل توجهی بر مقاومت فشاری ۲۸ روزه SCC می‌گذارد [۳]. مصطفی و همکاران، با

محدودیت‌ها و پیچیدگی‌های معماری سازه‌های جدید، در صورت در نظر گرفتن بتن به عنوان مصالح پایه، با چالش‌هایی روبروست، که عمدتاً مربوط به کارایی و روانی بتن و در عین حال حفظ مقاومت و دوام آن می‌باشد. بتن‌های خودتراکم^۱ به منظور رفع دغدغه‌های طراحان و صاحبان کار، از قبیل: صعوبت بتن‌ریزی در حجم‌های بالا و متراکم ساختن آن و همچنین به جهت استفاده از بتن به عنوان یک مصالح نهایی و نمایان در پروژه‌های عمرانی، برای اولین بار توسط اوکامورا در اواخر دهه ۱۹۸۰ به منظور دستیابی به سازه‌های پایدار در کشور ژاپن توسعه یافت [۱]. بعدها موسسه اروپایی EFNARC در سال ۲۰۰۲ به منظور حفظ انسجام در روند طراحی این نوع بتن‌ها، راهنمای بتن خودتراکم را منتشر کرد [۲].

- 2 Silica Fume
- 3 Pumice Powder
- 4 High-Range Water-Reducer Admixture(HRWRA)
- 5 Viscosity Modifying Admixture(VMA)

- 1 Self-Compacting concrete (SCC)

* نویسنده عهده‌دار مکاتبات: e.jahani@umz.ac.ir

حقوق مؤلفین به نویسندگان و حقوق ناشر به انتشارات دانشگاه امیرکبیر داده شده است. این مقاله تحت لایسنس آفرینندگی مردمی (Creative Commons License) در دسترس شما قرار گرفته است. برای جزئیات این لایسنس، از آدرس <https://www.creativecommons.org/licenses/by-nc/4.0/legalcode> دیدن فرمائید.



را تحت تاثیر پودر سرباره کوره آهن‌گدازی در بتن تازه و سخت شده مورد ارزیابی قرار دادند، آن‌ها دریافتند بهترین نسبت ترکیب مواد چسبنده به منظور سنجش مقاومت فشاری ۲۸ روزه، در متاکائولین ۱۰ درصد و سرباره کوره آهن‌گدازی ۲۵ درصد با مقدار ۶۴/۴ مگاپاسکال اتفاق می‌افتد [۸]. ژیان ژونگ و همکاران، با بررسی بتن خودتراکم حاوی پودر سنگ بازیافتی^۷ به نسبت‌های ۱۵، ۳۰ و ۴۵ درصد سیمان و همچنین با نسبت‌های آب به مواد سیمانی ۰/۴ و ۰/۵ اثر بخشی این مواد را مورد ارزیابی قرار دادند، آن‌ها دریافتند تا افزایش ۳۰٪ پودر بازیافتی کمترین تاثیر منفی را بر مقاومت فشاری ۲۸ روزه بتن‌های SCC خواهد داشت [۹].

با توجه به کیفیت و عملکرد بتن‌های خودتراکم و تعداد زیاد مواد افزودنی و جایگزین سیمان در این نوع از بتن‌ها، محققین به دنبال راه حلی برای جلوگیری از هدر رفت زمان و انرژی و همچنین رسیدن به نتایجی با درصد اطمینان بالا با توجه به تجربیات پیشین هستند. علوم کامپیوتر و شبکه‌های عصبی این امکان را به ما می‌دهد تا با ایجاد توابعی غیرخطی، بین متغیرها و خروجی‌ها روابطی را برقرار کنیم که در حالت سنتی، فرمول کردن آن‌ها امکان‌پذیر نمی‌باشد، مک کولاج و پیتر برای اولین بار در سال ۱۹۴۳ شبکه‌های عصبی مصنوعی^۸ بر اساس فهم ساختار بیولوژیکی شبکه‌های عصبی انسان را مطرح کردند [۱۰]. بعدها محققین با تعریف صورت مسائل متنوع که در حالت عادی از روش‌های سنتی و فرمول کردن مسائل قابل حل و ایجاد ارتباط بین ورودی‌ها و خروجی‌ها نبود، اقدام به حل مسائل پیچیده کردند. بتن‌های خودتراکم نیز با توجه به ماهیت خود نیازمند طیف وسیعی از ویژگی‌ها به منظور دستیابی به اهداف مختلف از قبیل قابلیت‌های بتن تازه (سنجش توانایی پرکنندگی، سنجش توانایی عبور، سنجش مقاومت در برابر جدا شدگی) و سخت شده (مقاومت فشاری در سنین مختلف، مقاومت کششی، مدول الاستیسیته و...) می‌باشد. سلورج و سیورمن، با استفاده از دو روش RSM^۹ و IFREMSVM^{۱۰} اقدام به بهینه‌سازی و پیش‌بینی مقاومت فشاری ۲۸ روزه و جریان اسلامپ بتن‌های خودتراکم کردند، آن‌ها با توجه به تعریف کردن ۴ ویژگی از جمله میزان سیمان، میزان خاکستر بادی، نسبت آب به مواد پودری و فوق روان کننده برای بتن‌های SCC، نهایتاً به دو هدف مقاومت فشاری و جریان اسلامپ که تابعی از ویژگی‌های مذکور بودند به صورت فرمول دست یافتند [۱۱]. عمار ایکتیدر و همکاران،

بررسی جایگزینی درصد بالای خاکستر بادی^۱ و میکروسیلیس به عنوان درصدی از مواد سیمانی، اقدام به برآورد مقاومت فشاری ۲۸ روزه نمونه‌ها کرده‌اند، آن‌ها با در نظر گرفتن ۴۰٪ خاکستر بادی و ۱۰٪ میکروسیلیس به ازای ۵۰٪ سیمان پرتلند به مقاومت ۸۵ مگاپاسکال رسیدند که نسبت به نمونه شاهد در همان آزمایش رشد ۵ درصدی مقاومت را نشان می‌دهد [۴]. پیرمحمدی، به بررسی اثر ژئولیت^۲ با درصدهای ۲، ۶، ۸، ۱۲ و ۱۵ و با عیار ۳۲۰، ۳۴۰، ۳۶۰، ۳۸۰ و ۴۰۰ کیلوگرم بر مترمکعب در SCC پرداخته است، او به این نتیجه رسید با افزایش میزان ژئولیت اگر چه در سنین پایین (۷ روز) مقاومت فشاری بتن کاهش می‌یابد، اما در سن ۲۸ روز مقاومت نمونه‌های خودتراکم با عیارهای ۳۲۰، ۳۴۰، ۳۶۰ و ۴۰۰ کیلوگرم بر مترمکعب ۸ درصد و با عیار ۳۶۰ کیلوگرم بر مترمکعب ۳ درصد افزایش می‌یابد [۵]. جیسنای سیلاپوردی و همکاران، با بررسی بتن‌های خودتراکم با پایه خاکستر بادی در دو مدل M30 و M40 اقدام به افزودن متاکائولین^۳ و میکروسیلیس با نسبت‌های حجمی ۵٪، ۱۰٪ و ۱۵٪ حجمی سیمان کرده‌اند، آن‌ها دریافتند در مدل M30 با افزودن ۱۰ درصد متاکائولین و ۱۰ درصد میکروسیلیس، مقاومت فشاری به ترتیب ۳۴٪ و ۳۸/۹٪ افزایش می‌یابد، همچنین در مدل M40 با در نظر گرفتن ۱۰ درصد متاکائولین، مقاومت فشاری ۲۸ روزه ۴۸/۲٪ افزایش و با افزودن ۱۰ درصد میکروسیلیس، مقاومت فشاری ۲۸ روزه ۴۸/۵٪ افزایش یافت [۶]. الیاس مولایی و همکاران، با جایگزینی جزئی خاکستر پوسته برنج^۴ به جای سیمان با درصدهای ۵، ۱۰، ۱۵ و ۲۰، عملکرد بتن خودتراکم را در سنین مختلف با نسبت‌های متغییر آب به مواد سیمانی (۰/۳۸، ۰/۴۴، ۰/۵، ۰/۵۶، ۰/۶۲، ۰/۶۸) مورد ارزیابی قرار داد، همچنین نمونه‌های ساخته شده دارای میزان ۲۲۰ کیلوگرم بر مترمکعب پودر سنگ آهک^۵ نیز در تمامی طرح‌های اختلاط بودند، که با افزایش ۵٪ خاکستر پوسته برنج نسبت به بتن شاهد، مقاومت فشاری ۸٪ افزایش و با افزایش نسبت آب به مواد سیمانی از ۰/۳۸ به ۰/۶۸ مقاومت فشاری SCC حاوی ۱۰٪ RHA نیز افزایش یافت [۷]. عبدا... عدنان و همکاران، با ایجاد یک ترکیب ۳ تایی از مواد چسبنده (سیمان، متاکائولین، سرباره کوره آهن‌گدازی) به طوری که میزان متاکائولین در تمامی نمونه‌ها ثابت (۱۰٪) و میزان GGBS با درصدهای متغییر ۱۶، ۲۰، ۲۵ و ۳۰، عملکرد بتن خودتراکم

- 1 Fly Ash
- 2 Zeolite
- 3 Metakaolin
- 4 Rice husk ash(RHA)
- 5 Limestone Powder
- 6 Ground Granulated Blast Furnace Slag(GGBS)

- 7 Recycled Powder
- 8 Artificial Neural Network (ANN)
- 9 Response surface methodology
- 10 intelligent fuzzy rule based enhanced multiclass support vector machine

۲۸ روزه بتن خودتراکم) استفاده شده است. به جهت ارزیابی عملکرد شبکه ANN از سه پارامتر ضریب همبستگی، ریشه میانگین مربعات خطا^{۱۰} و میانگین مربعات خطا^{۱۱} استفاده شده است، همچنین برای ارزیابی عملکرد شبکه LSTM از دو پارامتر ریشه میانگین مربعات خطا و میانگین مربعات خطای دو شبکه با هم، ریشه میانگین مربعات خطای دو شبکه با هم مورد ارزیابی قرار گرفته است. در این تحقیق در هر کدام از شبکه‌ها به ترتیب از سه الگوریتم Levenberg Mar-Scaled Conjugate, Bayesian Regularization, quardt Gradient در شبکه ANN و از سه الگوریتم Adam, Rmsprop, Sgdm در شبکه LSTM به جهت آموزش شبکه استفاده شده است، در نهایت بهترین الگوریتم آموزشی با توجه به پارامتر RMSE از هر شبکه به جهت مقایسه دو شبکه با هم انتخاب شد.

۲- توصیف شبکه‌های عصبی ۲-۱- شبکه ANN

ANN با ساختار MLP یا لایه‌های پرسپترون چند لایه از شبکه‌های عصبی مصنوعی Feed-forward با روش آموزش Backpropagation می‌باشد. این روش بر اساس کاهش گرادیان یا مشتق در هر مرحله استوار است. به طور کل شبکه دارای سه قسمت لایه ورودی، لایه پنهان و لایه خروجی می‌باشد. عملکرد شبکه به این صورت است که نمونه‌ها با هر تعداد ویژگی از قسمت ورودی، وارد می‌شود و پس از دریافت وزن‌های تصادفی در اولین تکرار وارد لایه پنهان شده و تابع فعال‌سازی و مقدار انحرافی بر آن اعمال شده و سپس به سمت خروجی می‌رود (شکل ۱).

$$\text{Sum Function: } \sum_{j=1}^m w_{ij} x_j + b_j \quad (1)$$

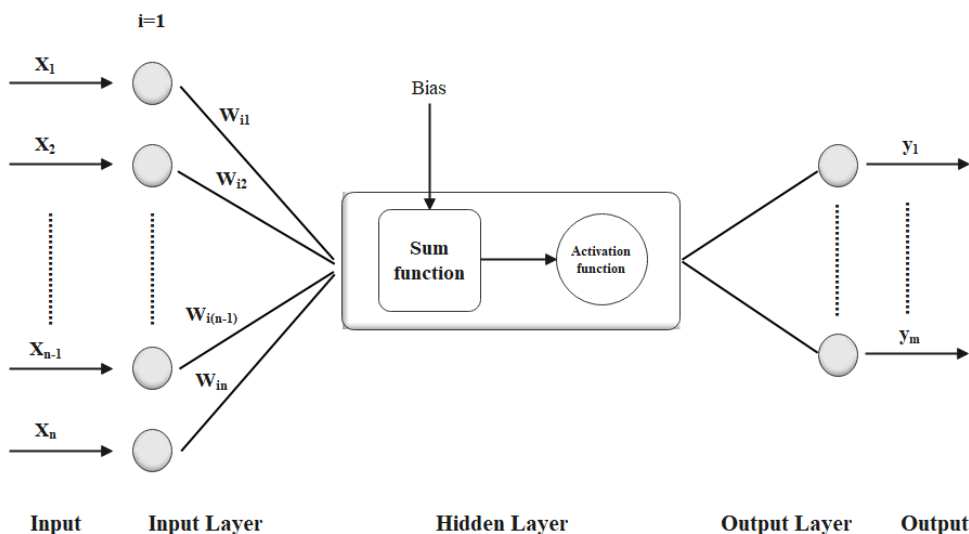
$$\text{Activation Function: } \frac{1}{1+e^{-x}} \text{ or } \frac{e^x - e^{-x}}{e^x + e^{-x}} \text{ and ...} \quad (2)$$

- 10 Root mean square error (RMSE)
11 Mean square error (MSE)

با استفاده از ۱۹۲ نمونه بتن حاوی خاکستر پسته برنج، از طریق محاسبات نرم^۱ به کمک چهار روش ANN^۲، ANFIS^۳، NLR^۴ و روش رگرسیون خطی با در نظر گرفتن ۶ ویژگی (سن، مقدار سیمان، خاکستر پسته برنج، میزان فوق روان‌ساز، آب و سنگدانه) برای هر یک از نمونه‌ها اقدام به پیش‌بینی مقاومت فشاری کردند [۱۲]، آن‌ها برای ارزیابی نتایج از تحلیل حساسیت^۴، آنالیز پارامتری^۵ و ضریب همبستگی^۶ استفاده کرده و به این نتیجه رسیدن، عملکرد ANN و ANFIS در این مورد خاص بهتر از دو روش دیگر است. محمود سرایه و همکاران، با در نظر گرفتن ۷ ویژگی از ۳۶۶ نمونه بتن SCC با محوریت میکروسلیس در سنین مختلف (۱، ۳، ۷، ۱۴، ۲۸، ۵۶، ۹۰، ۱۸۰، ۲۷۰ روزه) با کمک شبکه عصبی مصنوعی و الگوریتم آموزشی لونبرگ-مارکوارت اقدام به پیش‌بینی مقاومت فشاری بتن خودتراکم کرده‌اند، آن‌ها موفق شدند در بهترین حالت ضریب همبستگی ۰/۹۳ را از خروجی شبکه دریافت نمایند که نتیجه مورد قبول می‌باشد [۱۳]. همانطور که از موضوعات پژوهش‌های محققین پیرامون بتن، به خصوص بتن‌های خودتراکم مشخص است، جایگزینی مواد پرکننده، مواد پوزولانی و افزودنی با هدف کاهش هزینه، کاهش مصرف منابع طبیعی، کاهش انتشار دی اکسید کربن و بهبود ویژگی‌های تازه و سخت شده بتن خودتراکم به وضوح مشخص است، حال به منظور رسیدن به بهترین نتیجه با توجه به پراکندگی و تنوع زیاد مصالح، استفاده از محاسبات نرم و شبکه‌های عصبی به جهت صرفه‌جویی در زمان، هزینه و همچنین به مرور افزایش دقت، بسیار کارگشا می‌باشد.

هدف این تحقیق پیش‌بینی مقاومت فشاری ۲۸ روزه بتن خودتراکم با محوریت بررسی مواد پرکننده و اصلاح‌کننده لزجت و روانی با استفاده از دو شبکه عصبی ANN و LSTM^۷ با ماهیت یادگیری پس انتشار^۸ و یادگیری عمیق^۹ می‌باشد. در این پژوهش از ۳۲۰ نمونه بتن خودتراکم از محققین مختلف طی ده سال (جدول ۱) با ۱۴ ویژگی به عنوان ورودی‌ها شبکه عصبی و ۱ ویژگی به عنوان خروجی شبکه عصبی (مقاومت فشاری

- 1 Soft computing
- 2 Adaptive neuro-fuzzy inference system
- 3 Multiple nonlinear regression
- 4 Sensitivity analysis
- 5 Parametric analysis
- 6 Correlation factor (R)
- 7 Long short term memory
- 8 Backpropagation
- 9 Deep Learning



شکل ۱. ساختار کلی شبکه عصبی مصنوعی

Fig. 1. The general structure of the artificial neural network

پیش خور ما با یک شبکه RNN روبرو بوده، که در یادگیری عمیق از آن استفاده می‌شود.

Lstm از چهار بخش اصلی سلول یا حافظه شبکه، دروازه ورودی، دروازه خروجی و دروازه فراموشی تشکیل می‌شود. مشخصاً از دروازه ورودی داده‌ها وارد و از دروازه خروجی، هدف یا ویژگی خروجی، خارج می‌شود. اما حافظه شبکه و دروازه فراموشی این امکان رو به شبکه می‌دهد، که در یک بازه صفر و یک اثرگذاری حافظه قبلی را بر روی پاسخ‌های بعدی نشان دهد، به این صورت که اگر دروازه فراموشی مقدار یک بگیرد ۱۰۰ درصد حافظه نقش ایفا می‌کند و برعکس اگر صفر بگیرد طبیعتاً حافظه هیچ نقشی ایفا نمی‌کند، که این ویژگی بسیار نزدیک به حالت بیولوژیکی نورون‌های عصبی انسان بابت یادآوری و فراموشی برخی اطلاعات است. روابط حاکم بر Lstm به صورت زیر می‌باشد [۱۵]:


$$f_t = \sigma_g (W_f x_t + U_f h_{t-1} + b_f) \quad (4)$$

سپس در هر تکرار با توجه به اختلاف خروجی شبکه و مقدار هدف، شبکه سعی در کاهش خطا از طریق اصلاح وزن‌ها و بایاس‌ها می‌کند، بنابراین هدف در هر تکرار کاهش خطا بین خروجی شبکه و مقدار هدف می‌باشد. این روند به صورت رابطه زیر قابل بیان است:

$$w_i = w_j(t) + 2\eta(t_p - f_p). \text{Gradient activation function } .x_{ij} \quad (3)$$

۲-۲- شبکه عصبی LSTM

Lstm یا حافظه کوتاه مدت پایدار یک شبکه عصبی بازگشتی است، به این معنا که خروجی‌های شبکه مجدداً به عنوان ورودی در تکرار بعدی وارد شبکه می‌شود. Lstm اولین بار در اوایل دهه ۱۹۹۰ توسط Hochreiter مطرح و در اواخر همین دهه توسط Hochreiter و Schmidhuber گسترش یافت [۱۴]. که با استفاده از آن مشکل صفر شدن و بی‌نهایت شدن شبکه‌های بر پایه مشتقات، اصطلاحاً ونیش شدن شبکه به نوعی برطرف شد. خروجی Lstm شامل دو پارامتر c_t و h_t می‌باشد که به ترتیب معرف حافظه شبکه و خروجی هدف می‌باشد، که هر دوی این‌ها در گام بعدی با عنوان c_{t-1} و h_{t-1} وارد شبکه می‌شوند (شکل ۲)، بنابراین برخلاف شبکه



شکل ۲. ساختار شبکه عصبی حافظه کوتاه مدت پایدار (Lstm)

Fig. 2. Stable short-term memory neural network structure

شبکه در گام قبلی است. W_c و W_o ، W_i ، W_f به ترتیب بیانگر ماتریس وزن‌های دروازه‌های فراموشی، ورودی، خروجی و ماتریس وزن حافظه شبکه می‌باشد، که در هر تکرار در مسیر آموزش خود را به روزرسانی کرده و بر داده‌های ورودی اثر می‌گذارند. U_c و U_o ، U_i ، U_f به ترتیب بیانگر ماتریس‌های وزن بازگشتی دروازه فراموشی، دروازه ورودی، دروازه خروجی و ماتریس وزن بازگشتی حافظه شبکه می‌باشد، که در هر تکرار در مسیر آموزش خود را بروزرسانی کرده و بر داده‌های خروجی شبکه در تکرار قبلی اثر می‌گذارد. b_c و b_o ، b_i ، b_f به ترتیب بردارهای انحراف یا بایاس‌های هر دروازه می‌باشند، که در هر تکرار متناسب با انحراف مقادیر در هر مسیر به اعداد ما اضافه می‌شوند. σ_g ، σ_c و σ_h به ترتیب توابع فعال‌سازی سیگموئید، تانژانت هایپربولیک و هر تابع فعال‌سازی دیگر مثل توابع خطی و همچنین تانژانت هایپربولیک می‌تواند باشد. f_t ، i_t ، o_t و \tilde{c}_t به ترتیب مقدار تابع دروازه فراموشی تحت تابع فعال‌سازی سیگموئید، مقدار تابع دروازه ورودی تحت تابع فعال‌سازی سیگموئید، مقدار تابع دروازه خروجی، تحت تابع سیگموئید و مقدار تابع حافظه موقت شبکه تحت تابع فعال‌سازی تانژانت هایپربولیک می‌باشد. مقادیر h_t و c_t در روابط ۸ و ۹ خروجی حافظه شبکه و خروجی هدف شبکه می‌باشد، همانطور که در شکل ۲ مشخص است

$$i_t = \sigma_g (W_i x_t + U_i h_{t-1} + b_i) \quad (5)$$

$$o_t = \sigma_g (W_o x_t + U_o h_{t-1} + b_o) \quad (6)$$

$$\tilde{c}_t = \sigma_c (W_c x_t + U_c h_{t-1} + b_c) \quad (7)$$

$$c_t = f_t \circ c_{t-1} + i_t \circ \tilde{c}_t \quad (8)$$

$$h_t = o_t \circ \sigma_h (c_t) \quad (9)$$

در روابط ۴ تا ۷ که از نظر ظاهری شبیه می‌باشند پارامترهای x_t و h_{t-1} مشترک بوده و به ترتیب معرف بردار ورودی شبکه و خروجی

در این مطالعه با توجه به تنوع زیاد مواد افزودنی در بتن‌های خودتراکم، چه با خاصیت پوزولانی و جایگزین سیمان و چه با خاصیت پرکنندگی و حذف فضای خالی بتن، اقدام به استفاده از بخش زیادی از مواد رایج و مورد تحقیق پژوهشگران در زمینه بتن خودتراکم شده است.

۳-۲- معماری و آموزش داده‌ها

روند آموزش نمونه‌ها در شبکه ANN به این صورت است که ۸۰ درصد نمونه‌ها (۲۵۶ عدد) برای آموزش و ۱۰ درصد نمونه‌ها (۳۲ عدد) برای آزمایش و ۱۰ درصد نمونه‌ها (۳۲ عدد) برای اعتبارسنجی مورد استفاده قرار گرفته است (Validation یا اعتبارسنجی در واقع داده‌هایی است که شبکه از آن برای توقف آموزش شبکه در راستای جلوگیری از Overtraining استفاده می‌کند، همچنین هدف شبکه پیش‌بینی مقاومت فشاری بتنی است که از ورودی‌های آن بی‌اطلاع است (به نوعی داده‌های جدید)، که داده‌های Validation این نقش را نسبت به داده‌های Test ایفا می‌کند). سپس همانند شکل ۴ در نظر گرفتن تعداد نورون‌های لایه پنهان از تعداد ۱۰ تا ۳۰ به صورت اعداد زوج اقدام به آزمون خطا به جهت رسیدن به بهینه‌ترین تعداد نورون‌ها در لایه پنهان شده است.

در روند آموزش شبکه عصبی از سه الگوریتم Levenberg Mar-Conju- Scaled و Bayesian Regularization، quardt و gate Gradient استفاده شده است. به جهت تصادفی بودن مقادیر وزن‌ها در شروع آموزش و تغییر پارامترهای عملکرد شبکه (R و MSE)، بعد از انتخاب تعداد نورون‌های لایه پنهان و الگوریتم مورد نظر برای آموزش شبکه، آموزش را حداکثر ۵ بار تکرار کرده و بهترین عملکرد شبکه ثبت شده است. در مجموع ۱۶۵ تکرار آموزش به جهت ثبت بهترین عملکرد انجام گرفته است (جدول‌های ۳ تا ۵).

همچنین برای آموزش شبکه LSTM ۸۰ درصد نمونه‌ها برای آموزش (۲۵۶ نمونه) و ۲۰ درصد نمونه‌ها (۶۵ نمونه) برای آزمایش در نظر گرفته شد. برخلاف شبکه ANN به جای استفاده از خطای ارزیابی^۱ به جهت توقف شبکه از حداکثر تکرار ۲۵۰ برای توقف شبکه بهره گرفته شده است. در شبکه LSTM نیز از سه الگوریتم متفاوت Adam، Rmsprop و Sgdm استفاده شده و بهترین عملکرد شبکه با پارامترهای MES و RMSE مورد ارزیابی قرار گرفت. در این شبکه نیز بعد از مشخص کردن تعداد نورون‌ها و الگوریتم آموزشی، یک تکرار در نظر گرفته شده که مجموعاً ۳۳ تکرار به جهت آموزش شبکه برای ثبت بهترین عملکرد انجام شده است (جدول‌های ۷ تا ۹).

حاصل ضرب المان به المان بردارهای f_i و c_{i-1} و حاصل جمع آن‌ها با حاصل ضرب المان به المان مقدار بردار خروجی از دروازه ورودی (i_i) (با بردار حافظه موقت (\tilde{c}_i) حافظه شبکه در یک تکرار حاصل می‌شود و همچنین با اعمال مجدد یک تابع فعال‌سازی بر حافظه شبکه ($\sigma_h(c_i)$) و ضرب المان به المان آن بردار در بردار خروجی از دروازه خروجی (O_i)، خروجی شبکه (h_i) در یک تکرار حاصل می‌شود.

۳-۳- مدل پیش‌بینی با استفاده از شبکه ANN و LSTM

هدف این تحقیق توسعه مدل‌های شبکه ANN و LSTM با استفاده از پارامترهای تاثیرگذار در مقاومت فشاری ۲۸ روزه بتن خودتراکم می‌باشد. در این مطالعه با تمرکز بر روی پوزولان‌ها و افزودنی‌های رایج، با کمک گرفتن از دو شبکه عصبی و ۳ الگوریتم آموزشی مختلف برای هر شبکه، اقدام به ارزیابی عملکرد شبکه شده است. به جهت ارزیابی عملکرد از سه پارامتر میانگین مربعات خطا (MSE)، ریشه میانگین مربعات خطا (RMSE) و ضریب همبستگی (R) با کمک ابزارهای نرم‌افزار متلب (بعد تشکیل شبکه با داده‌های مورد آموزش (گرفتن net)، کفایت به ازای هر داده‌ای که پژوهشگر مدنظر دارد" برای مثال اگر در بتن خودتراکم مورد نظر هر کدام از فیلرها را نداریم کفایت صفر وارد کنیم" به صورت اعداد منطقی وارد ماتریس کرده تا شبکه مقاومت فشاری متناظر را پیش‌بینی کند) استفاده شده است.

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (t_i - o_i)^2} \quad (10)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (t_i - o_i)^2}{\sum_{i=1}^n (o_i)^2} \quad (11)$$

۳-۱- جمع آوری و تحلیل داده‌ها

در این پژوهش از ۳۲۰ نمونه بتن خودتراکم از محققین مختلف در بازه زمانی ده ساله (جدول ۱) که هر کدام از نمونه‌های ورودی به شبکه دارای ۱۴ ویژگی، شامل ۴ ویژگی اصلی (نسبت آب به مواد پودری، مجموع سنگدانه شامل ریزدانه و درشت‌دانه، فوق روان کننده و سیمان) و ۱۰ ویژگی فرعی (جدول ۲ و شکل ۳) می‌باشند، استفاده شده است. همچنین نمونه‌ها دارای یک ویژگی خروجی مربوط به مقاومت فشاری ۲۸ روزه نیز می‌باشند.

جدول ۱. منابع نمونه‌های مورد استفاده در شبکه عصبی مصنوعی


Table 1. Source of samples used in artificial neural networks

ردیف	منابع	تعداد داده‌ها	محدوده مقاومت فشاری [MPa]
۱	Davoodnabi and Safehian (2019) [16]	۲۱	۴۶-۸۵
۲	Abbasifar et al. (2019) [17]	۷	۷۱-۸۹
۳	Varjavand and Sobhaninia (2019) [18]	۴	۲۸-۳۹
۴	Khanzadi et al. (2018) [19]	۸	۴۴-۵۵
۵	Amirkhani et al. (2017) [20]	۲۱	۳۰-۵۳
۶	Ghoddousi et al. (2017) [21]	۱۴	۳۷-۴۷
۷	Razmara et al. (2017) [22]	۷	۳۳-۴۴
۸	Hoseini and Varastepour (2017) [23]	۵	۴۳-۵۴
۹	Khazali et al. (2017) [24]	۵	۵۰-۷۲
۱۰	Poorhosein (2016) [25]	۱۲	۳۳-۶۴
۱۱	Nassirnia (2016) [26]	۱۰	۲۸-۳۷
۱۲	Meshkini and Pirmohammadi (2016) [27]	۷	۳۶-۴۳
۱۳	Hassan et al. (2015) [28]	۳۳	۲۳-۵۵
۱۴	Noori et al. (2015) [29]	۱۲	۳۷-۶۰
۱۵	Eftekhari et al. (2015) [30]	۵	۳۸-۴۸
۱۶	Varastepour et al. (2015) [31]	۴	۱۷-۳۳
۱۷	Berenjian and Noori (2014) [32]	۸	۳۷-۴۸
۱۸	Ghasemi et al. (2013) [33]	۱۰	۲۵-۴۹
۱۹	Aslani et al. (2013) [34]	۶	۲۶-۳۲
۲۰	Sargazi et al. (2013) [35]	۵	۳۳-۴۷
۲۱	Khazaeni et al. (2013) [36]	۴	۳۲-۳۹
۲۲	Madandoust and Mousavi (2012) [37]	۱۵	۳۱-۵۴
۲۳	Ranjbar et al. (2012) [38]	۶	۵۵-۶۵
۲۴	Sadrmomtazi et al. (2011) [39]	۱۲	۳۹-۵۹
۲۵	Farshadfar et al. (2011) [40]	۱۰	۵۹-۷۰
۲۶	Askari et al. (2011) [41]	۴	۶۰-۶۴
۲۷	Guneyisi et al. (2009) [42]	۶۵	۳۰-۹۹
کل		۳۲۰	۱۷-۹۹

جدول ۲. تعداد و درصد ویژگی‌های فرعی مورد استفاده در شبکه عصبی


Table 2. Number and percentage of sub-features used in the neural network

ردیف	مواد پودری پرکننده	تعداد داده‌ها	درصد داده‌ها
۱	Limestone Powder (LP)	۵۶	۱۷/۵
۲	Recycled Powder (RP)	۲۹	۹/۱
۳	Fly Ash (FA)	۴۷	۱۴/۷
۴	Silica Fume (SF)	۸۴	۲۶/۲
۵	Zeolite (Z)	۲۴	۷/۵
۶	Metakaolin (MK)	۶۲	۱۹/۴
۷	Ground Granulated Blast Furnace Slag (GGBS)	۶۸	۲۱/۲
۸	Rice Husk Ash (RHA)	۱۹	۵/۹
۹	Pumice Powder (P)	۲۱	۶/۵
۱۰	Viscosity Modifying Admixture (VMA)	۱۹	۵/۹



شکل ۳. درصد ویژگی‌های فرعی مورد استفاده در شبکه

Fig. 3. Percentage of sub-features used in the neural network



شکل ۴. شماتیک عملکرد یک نمونه از داده‌های ورودی شبکه عصبی به صورت MLP

Fig.4. Schematic of the performance of a sample of neural network input data in MLP

۴- آموزش و ثبت داده‌ها

همانطور که در آزمایشات مشخص است، علاوه بر ردیف ۳ از جدول ۳، سایر ردیف‌ها نیز در بازه مورد نظر ضریب همبستگی وجود دارند، لذا ردیف ۳ در مجموع به اختلاف ناچیز نسبت به سایر ردیف‌ها بهترین عملکرد را دارد (شکل ۵).

همچنین در جدول ۴ همان داده‌ها با الگوریتم Bayesian Regularization آموزش داده شده‌اند. مشابه روند آموزش شبکه با الگوریتم Levenberg Marquardt، این بار نیز از تعداد ۱۰ نورون تا ۳۰ نورون در لایه پنهان با حداکثر ۵ تکرار آموزش، بهره گرفته شد.

با بررسی خروجی‌های موجود در ردیف‌های جدول ۴ درمی‌یابیم، اعداد بسیار به هم نزدیک می‌باشند و این به این معناست که لزوماً انتخاب یک ردیف به عنوان ردیف بهینه به معنی نفی سایر ردیف‌ها با مفهوم ساختارهای معماری متفاوت نمی‌باشد، لذا به دنبال اعدادی هستیم که علاوه بر مقدار بهینه در آموزش، دارای مقدار متناسب در تست یا آزمایش نیز باشند. بنابراین ردیف ۱۱ از جدول فوق با الگوریتم آموزشی Bayesian Regularization با ریشه میانگین مربعات خطا در آموزش برابر ۳/۵۶ و در آزمایش برابر با ۴/۹۷ و همچنین ضریب همبستگی در آموزش برابر ۰/۹۷۸۰ و در آزمایش

همانطور که در جدول ۳ قابل مشاهده است، نمونه‌ها با شبکه ANN و الگوریتم Levenberg Marquardt آموزش داده شده‌اند و عملکرد شبکه با پارامترهای MSE، RMSE و R مورد ارزیابی قرار گرفت. مشخصاً بهترین عملکرد شبکه، مربوط به ردیف سه با معماری ۱۴ نورون در لایه میانی و با پنج تکرار آموزش، برابر با ریشه میانگین مربعات خطای ۳/۹۱ در آموزش و ۷/۰۴ در آزمایش و ضریب همبستگی ۰/۹۷۳۰ در آموزش و ۰/۹۲۱۰ در آزمایش می‌باشد.

اسمیت در سال ۱۹۸۶ برای ضریب همبستگی در بازه صفر و یک، پیشنهاد زیر را مطرح کرد [۴۳ و ۴۴]:

اگر $0.8 \leq |R|$ باشد، ارتباط قوی بین دو مجموعه از متغیرها وجود دارد.


اگر $0.2 < |R| < 0.8$ باشد، ارتباط بین دو مجموعه از متغیرها وجود دارد.

اگر $|R| \leq 0.2$ باشد، ارتباط ضعیف بین دو مجموعه از متغیرها وجود دارد.

جدول ۳. عملکرد نمونه‌ها در شبکه ANN با الگوریتم آموزشی Levenberg Marquardt

Table 3. Performance of samples in ANN network with levenberg marquardt training algorithm

ویژگی‌ها		تعداد نمونه‌ها		ارزیابی (عملکرد)		الگوریتم آموزشی		
۱۴		۳۲۰		Mean Squared Error		Levenberg-Marquardt		
داده‌های آزمایش		اعتبارسنجی		داده‌های آموزش				
تعداد	(%)	تعداد	(%)	تعداد	(%)	تعداد	(%)	
۳۲	۱۰	۳۲	۱۰	۲۵۶	۸۰			
ردیف	تعداد نورون‌های لایه پنهان	R	MSE		RMSE		R	
			آموزش	آزمایش	آموزش	آزمایش		
۱	۱۰	R4	۵۳/۲۵	۹۰/۸۸	۷/۲۹	۹/۵۳	۰/۹۰۵۰	۰/۸۵۴۷
۲	۱۲	R2	۳۴/۱۸	۵۹/۰۵	۵/۸۴	۷/۶۸	۰/۹۴۰۹	۰/۸۶۷۶
۳	۱۴	R5	۱۵/۳۵	۴۹/۶۵	۳/۹۱	۷/۰۴	۰/۹۷۳۰	۰/۹۲۱۰
۴	۱۶	R4	۴۱/۱۲	۵۱/۲۳	۶/۴۱	۷/۱۵	۰/۹۲۵۸	۰/۹۰۶۹
۵	۱۸	R2	۱۴/۴۸	۶۰/۵۳	۳/۸۰	۷/۷۸	۰/۹۷۳۶	۰/۸۹۵۸
۶	۲۰	R4	۳۳/۱۲	۷۷/۹۴	۵/۷۵	۸/۸۲	۰/۹۳۹۶	۰/۹۱۳۶
۷	۲۲	R3	۱۵/۶۸	۶۰/۹۰	۳/۹۵	۷/۸۰	۰/۹۷۱۷	۰/۸۸۵۲
۸	۲۴	R5	۲۶/۴۲	۶۸/۴۷	۵/۱۴	۸/۲۷	۰/۹۴۹۸	۰/۹۰۲۳
۹	۲۶	R3	۱۹/۶۷	۸۴/۵۱	۴/۴۳	۹/۱۹	۰/۹۶۳۶	۰/۹۰۵۰
۱۰	۲۸	R2	۱۱/۳۲	۸۲/۶۸	۳/۳۶	۹/۰۹	۰/۹۷۹۹	۰/۸۸۳۲
۱۱	۳۰	R2	۳۰/۶۶	۸۸/۱۱	۵/۵۳	۹/۳۸	۰/۹۴۵۳	۰/۸۷۲۵



شکل ۵. معماری شبکه ANN با تعداد نورون‌های بهینه با استفاده از الگوریتم آموزشی Levenberg Marquardt

Fig. 5. ANN Network architecture with optimal number of neurons using levenberg marquardt training algorithm

عملکرد همانند الگوریتم آموزشی Bayesian Regularization مربوط به ردیف ۱۱ با ۳۰ نورون در لایه پنهان و با مقادیر ریشه میانگین مربعات خطا، $۷/۴۰$ در آموزش و $۷/۸۰$ در آزمایش می‌باشد. همچنین مشاهده می‌شود مقادیر ضریب همبستگی در آموزش برابر $۰/۸۹۴۴$ و در آزمایش $۰/۸۵۸۲$ می‌باشد، که علاوه بر اینکه با توجه به معیار اسمیت ارتباط قوی بین داده‌ها برقرار است در مجموع آموزش و آزمایش از باقی حالت‌های تعریف شده در جدول ۵ عملکرد بهتری دارد (شکل ۷).


برابر با $۰/۹۴۸۴$ به دلیل نزدیک‌تر بودن مقدار RMSE به یک به عنوان بهینه‌ترین ساختار معماری نسبت به سایر ردیف‌ها در نظر گرفته شده که علاوه بر قرار گرفتن در بهترین عملکرد معیار اسمیت، در مجموع آموزش و آزمایش از باقی حالت‌ها عملکرد بهتری دارد (شکل ۶).

در نهایت سومین الگوریتم آموزشی مورد استفاده در شبکه ANN، الگوریتم آموزشی Scaled Conjugate Gradient می‌باشد، که با توجه به نتایج حاصل در جدول ۵ با استدلال پاراگراف قبل درمی‌یابیم بهترین

جدول ۴. عملکرد نمونه‌ها در شبکه ANN با الگوریتم آموزش Bayesian Regularization

Table 4. Performance of samples in ANN network with Bayesian Regularization training algorithm

ویژگی‌ها	تعداد نمونه‌ها	ارزیابی (عملکرد)	الگوریتم آموزشی
۱۴	۳۲۰	Mean Squared Error	Bayesian Regularization
داده‌های آزمایش		داده‌های آموزش	
تعداد	(%)	تعداد	(%)
۳۲	۱۰	۲۵۶	۸۰
R		MSE	
آموزش	آزمایش	آموزش	آزمایش
۰/۹۷۸۳	۵/۵۴	۱۲/۰۶	۳۰/۷۲
۰/۹۷۸۸	۶/۵۳	۱۱/۷۵	۴۲/۷۵
۰/۹۸۱۱	۷/۲۲	۱۰/۵۹	۵۲/۱۵
۰/۹۷۵۷	۵/۹۳	۱۳/۷۹	۳۵/۲۰
۰/۹۸۱۹	۸/۰۳	۱۰/۳۱	۶۴/۶۰
۰/۹۸۳۹	۶/۷۵	۹/۲۰	۴۵/۶۲
۰/۹۸۵۴	۷/۲۶	۸/۴۴	۵۲/۷۰
۰/۹۸۰۹	۶/۸۱	۱۰/۶۶	۴۶/۳۸
۰/۹۷۹۱	۶/۵۷	۱۱/۷۵	۴۳/۲۶
۰/۹۸۰۱	۷/۰۶	۱۱/۰۷	۴۹/۸۴
۰/۹۷۸۰	۴/۹۷	۱۲/۷۰	۲۴/۷۷




شکل ۶. معماری شبکه ANN با تعداد نورون‌های بهینه با استفاده از الگوریتم آموزش Bayesian Regularization

Fig. 6. ANN Network architecture with optimal number of neurons using Bayesian Regularization training algorithm

جدول ۵. عملکرد نمونه‌ها در شبکه ANN با الگوریتم آموزش Scaled Conjugate Gradient

Table 5. Performance of samples in ANN network with Scaled Conjugate Gradient training algorithm

ویژگی‌ها		تعداد نمونه‌ها		ارزیابی (عملکرد)		الگوریتم آموزشی		
۱۴		۳۲۰		Mean Squared Error		Scaled Conjugate Gradient		
داده‌های آزمایش			اعتبارسنجی			داده‌های آموزش		
تعداد	(%)	تعداد	(%)	تعداد	(%)	تعداد	(%)	
۳۲	۱۰	۳۲	۱۰	۲۵۶	۸۰			
ردیف	تعداد نورون‌های لایه پنهان	R	MSE		RMSE		R	
			آموزش	آزمایش	آموزش	آزمایش	آموزش	آزمایش
۱	۱۰	R2	۱۰۸/۳۱	۹۱/۵۴	۱۰/۴۰	۹/۵۶	۰/۷۸۸۹	۰/۸۴۸۹
۲	۱۲	R3	۱۲۶/۹۹	۱۳۷/۷۴	۱۱/۲۶	۱۱/۷۳	۰/۷۳۶۲	۰/۸۰۹۸
۳	۱۴	R1	۱۲۰/۰۵	۱۳۰/۸۳	۱۰/۹۵	۱۱/۴۲	۰/۷۵۸۲	۰/۷۸۷۶
۴	۱۶	R4	۱۰۱/۷۹	۱۳۳/۲۶	۱۰/۰۹	۱۱/۵۴	۰/۸۰۲۹	۰/۷۷۷۵
۵	۱۸	R4	۸۰/۷۱	۹۴/۵۷	۸/۹۸	۹/۷۲	۰/۸۴۹۲	۰/۸۱۷۲
۶	۲۰	R5	۸۰/۹۳	۱۰۸/۳۱	۸/۹۹	۱۰/۴۰	۰/۸۳۳۹	۰/۸۲۹۸
۷	۲۲	R2	۱۱۹/۹۹	۱۲۹/۷۸	۱۰/۹۵	۱۱/۳۹	۰/۷۶۱۹	۰/۷۳۷۲
۸	۲۴	R3	۹۵/۴۹	۸۲/۷۴	۹/۷۷	۹/۰۹	۰/۸۲۸۳	۰/۸۱۲۶
۹	۲۶	R3	۶۵/۶۵	۱۱۸/۱۴	۸/۱۰	۱۰/۸۷	۰/۸۸۰۰	۰/۷۹۶۲
۱۰	۲۸	R5	۶۹/۲۰	۱۴۴/۵۴	۸/۳۲	۱۲/۰۲	۰/۸۶۳۸	۰/۷۰۸۹
۱۱	۳۰	R1	۵۴/۷۹	۶۰/۹۶	۷/۴۰	۷/۸۰	۰/۸۹۴۴	۰/۸۵۸۲



شکل ۷. معماری شبکه ANN با تعداد نورون‌های بهینه با استفاده از الگوریتم آموزش Scaled Conjugate Gradient

Fig. 7. ANN Network architecture with optimal number of neurons using Scaled Conjugate Gradient training algorithm

جدول ۶. مقایسه عملکرد شبکه ANN با سه الگوریتم آموزشی مختلف

Table 6. Comparison of ANN network performance with three different training algorithm

الگوریتم آموزشی	عملکرد شبکه با ساختار معماری ۳۰ نورون در لایه میانی				عملکرد شبکه با بهترین ساختار معماری در هر الگوریتم آموزشی			
	RMSE		R		RMSE		R	
	آموزش	آزمایش	آموزش	آزمایش	آموزش	آزمایش	آموزش	آزمایش
Levenberg Marquardt	۵/۵۳	۹/۳۸	۰/۹۴۵۳	۰/۸۷۲۵	۳/۹۱	۷/۰۴	۰/۹۷۳۰	۰/۹۲۱۰
Bayesian Regularization	۳/۵۶	۴/۹۷	۰/۹۷۸۰	۰/۹۴۸۴	۳/۵۶	۴/۹۷	۰/۹۷۸۰	۰/۹۴۸۴
Scaled Conjugate Gradient	۷/۴۰	۷/۸۰	۰/۸۹۴۴	۰/۸۵۸۲	۷/۴۰	۷/۸۰	۰/۸۹۴۴	۰/۸۵۸۲

همانطور که از جدول ۵ مشخص است، اگر چه ردیف ۱۱ با ۳۰ نورون در لایه پنهان همانند الگوریتم آموزشی Bayesian Regularization بهترین عملکرد را هنگامی که از الگوریتم Scaled Conjugate Gradient استفاده می‌کنیم داشته است، اما در مقایسه با الگوریتم آموزشی Bayesian Regularization در حالت مشابه و الگوریتم آموزشی Levenberg Marquardt با ۱۴ نورون در لایه پنهان عملکرد ضعیف‌تری داشته است.

برای مقایسه سه الگوریتم آموزشی در شبکه ANN با هم، از آنجایی که دو الگوریتم Bayesian و Scaled Conjugate Gradient Regularization در تعداد نورون‌های لایه پنهان با هم برابر هستند، می‌توان علاوه بر اینکه الگوریتم آموزشی Levenberg Marquardt را با ۱۴ نورون در لایه میانی با آن‌ها در مقام مقایسه برآورد، به طور جداگانه نیز می‌توان با تعداد نورون‌های ۳۰ با آن‌ها مقایسه کرد. همانطور که در جدول ۶ قابل مشاهده است، با توجه به اینکه هر چه RMSE و R به یک نزدیک‌تر باشند، نشان دهنده عملکرد بهتر شبکه می‌باشد، بهترین عملکرد شبکه از بین سه الگوریتم آموزشی مورد نظر مربوط به الگوریتم Bayesian Regularization می‌باشد. اگر چه در حالت ۳۰ نورون در لایه میانی الگوریتم آموزشی Scaled Conjugate Gradient از الگوریتم آموزشی Levenberg Marquardt مقدار مناسب‌تری دارد (۷/۸۰)، اما به طور کل بعد از الگوریتم آموزشی Bayesian Regularization، الگوریتم آموزشی Levenberg Marquardt نسبت به الگوریتم آموزشی Scaled Conjugate Gradient اعداد بهتری را به ثبت می‌رساند.

رسانیده است و عملکرد بهتری داشته است (جدول ۶). بهترین عملکرد شبکه ANN با الگوریتم‌های آموزشی مختلف در قالب نمودار در شکل‌های ۸ الی ۱۰ نیز قابل مشاهده می‌باشد.


در ادامه برای گسترش و آموزش شبکه عصبی LSTM، در ابتدا از الگوریتم Adam استفاده شده است. با توجه به جدول ۷، ۸۰ درصد نمونه‌ها برای آموزش و ۲۰ درصد نمونه‌ها برای آزمایش منظور شده و به جهت نقطه توقف آموزش شبکه، ۲۵۰ بار تکرار معیار قرار گرفته است، لذا همانند شبکه ANN از ۱۰ نورون در لایه میانی ساختار معماری شبکه شروع و به ۳۰ نورون خاتمه یافت، و در نهایت عملکرد شبکه با پارامتر RMSE در یک تکرار آموزش مورد ارزیابی قرار گرفت.

همانطور که پیشتر بیان شد، هر چه مقدار RMSE کمتر و به یک نزدیک‌تر باشد، خطای شبکه کمتر بوده و به نوعی اختلاف بین خروجی شبکه و مقادیر هدف، که در اینجا مقاومت فشاری ۲۸ روزه می‌باشد، کمتر است. لذا همانطور که از جدول ۷ مشخص است، کمترین مقدار با اختلاف ناچیز نسبت به سایر ردیف‌ها مربوط به ردیف ۶ با ۲۰ نورون در لایه پنهان و ریشه میانگین مربعات خطای ۱۰/۰۸۵۶ می‌باشد، که نشان دهنده عملکرد بهتر شبکه نسبت به سایر معماری‌ها در این مجموعه است.

الگوریتم آموزشی بعدی که در ساختار شبکه LSTM، داده‌ها به کمک آن آموزش داده شد، الگوریتم‌های Rmsprop و Sgdm می‌باشند، که با همان مکانیسم پیشین، به صورتی که ۲۵۶ داده را به عنوان آموزش و ۶۵ نمونه را به عنوان تست با ۲۵۰ تکرار در نظر گرفته شد، که نتایج آن در جداول ۸ و ۹ قابل مشاهده است.


همانطور که از جدول ۵ مشخص است، اگر چه ردیف ۱۱ با ۳۰ نورون در لایه پنهان همانند الگوریتم آموزشی Bayesian Regularization بهترین عملکرد را هنگامی که از الگوریتم Scaled Conjugate Gradient استفاده می‌کنیم داشته است، اما در مقایسه با الگوریتم آموزشی Bayesian Regularization در حالت مشابه و الگوریتم آموزشی Levenberg Marquardt با ۱۴ نورون در لایه پنهان عملکرد ضعیف‌تری داشته است.

برای مقایسه سه الگوریتم آموزشی در شبکه ANN با هم، از آنجایی که دو الگوریتم Bayesian و Scaled Conjugate Gradient Regularization در تعداد نورون‌های لایه پنهان با هم برابر هستند، می‌توان علاوه بر اینکه الگوریتم آموزشی Levenberg Marquardt را با ۱۴ نورون در لایه میانی با آن‌ها در مقام مقایسه برآورد، به طور جداگانه نیز می‌توان با تعداد نورون‌های ۳۰ با آن‌ها مقایسه کرد. همانطور که در جدول ۶ قابل مشاهده است، با توجه به اینکه هر چه RMSE و R به یک نزدیک‌تر باشند، نشان دهنده عملکرد بهتر شبکه می‌باشد، بهترین عملکرد شبکه از بین سه الگوریتم آموزشی مورد نظر مربوط به الگوریتم Bayesian Regularization می‌باشد. اگر چه در حالت ۳۰ نورون در لایه میانی الگوریتم آموزشی Scaled Conjugate Gradient از الگوریتم آموزشی Levenberg Marquardt مقدار مناسب‌تری دارد (۷/۸۰)، اما به طور کل بعد از الگوریتم آموزشی Bayesian Regularization، الگوریتم آموزشی Levenberg Marquardt نسبت به الگوریتم آموزشی Scaled Conjugate Gradient اعداد بهتری را به ثبت می‌رساند.




شکل ۸. نمودارهای خطا و ضریب همبستگی شبکه ANN با در نظر گرفتن الگوریتم Levenberg Marquardt

Fig. 8. Error graphs and correlation coefficient of ANN network using Levenberg Marquardt algorithm



شکل ۹. نمودارهای خطا و ضریب همبستگی شبکه ANN با در نظر گرفتن الگوریتم Bayesian Regularization

Fig. 9. Error graphs and correlation coefficient of ANN network Bayesian Regularization algorithm



شکل ۱۰. نمودارهای خطا و ضریب همبستگی شبکه ANN با در نظر گرفتن الگوریتم Scaled Conjugate Gradient

Fig. 10. Error graphs and correlation coefficient of ANN network Scaled Conjugate Gradient algorithm

جدول ۷. عملکرد نمونه‌ها در شبکه LSTM با الگوریتم آموزشی Adam

Table 7. Performance of samples in Lstm network with Adam training algorithm

الگوریتم آموزشی		ارزیابی (عملکرد)		تعداد نمونه‌ها	ویژگی‌ها
Adam		Root Mean Squared Error		۳۲۰	۱۴
داده‌های آموزش			داده‌های آزمایش		ماکزیمم تکرار
(%)	تعداد	(%)	تعداد	۲۵۰	
۸۰	۲۵۶	۲۰	۶۵		
ردیف	تعداد نورون‌های لایه پنهان		MSE	RMSE	
۱	۱۰	R1	۱۰۷/۴۴۵۶	۱۰/۳۶۵۶	
۲	۱۲	R1	۱۱۴/۵۵۰۰	۱۰/۷۰۲۸	
۳	۱۴	R1	۱۲۳/۰۵۲۴	۱۱/۰۹۲۹	
۴	۱۶	R1	۱۰۲/۵۰۰۰	۱۰/۱۲۴۲	
۵	۱۸	R1	۱۳۰/۱۰۶۰	۱۱/۴۰۶۴	
۶	۲۰	R1	۱۰۱/۷۲۰۰	۱۰/۰۸۵۶	
۷	۲۲	R1	۱۳۲/۵۸۶۰	۱۱/۵۱۴۶	
۸	۲۴	R1	۱۰۷/۳۳۵۸	۱۰/۳۶۰۳	
۹	۲۶	R1	۱۱۳/۲۴۷۹	۱۰/۶۴۱۸	
۱۰	۲۸	R1	۱۶۱/۳۰۲۷	۱۲/۷۰۰۵	
۱۱	۳۰	R1	۱۹۳/۳۸۵۱	۱۳/۹۰۶۳	

جدول ۸. عملکرد نمونه‌ها در شبکه LSTM با الگوریتم آموزشی Rmsprop

Table 8. Performance of samples in Lstm network with Rmsprop training algorithm

الگوریتم آموزشی		ارزیابی (عملکرد)		تعداد نمونه‌ها	ویژگی‌ها
Rmsprop		Root Mean Squared Error		۳۲۰	۱۴
داده‌های آموزش			داده‌های آزمایش		ماکزیمم تکرار
(%)	تعداد	(%)	تعداد	۲۵۰	
۸۰	۲۵۶	۲۰	۶۵		
ردیف	تعداد نورون‌های لایه پنهان		MSE	RMSE	
۱	۱۰	R1	۱۹۱/۵۱۷۹	۱۳/۸۳۹۰	
۲	۱۲	R1	۹۴/۱۴۶۲	۹/۷۰۲۹	
۳	۱۴	R1	۱۱۳/۸۹۱۵	۱۰/۶۷۲۰	
۴	۱۶	R1	۱۱۲/۷۳۱۳	۱۰/۶۱۷۵	
۵	۱۸	R1	۸۵/۱۱۳۵	۹/۲۲۵۷	
۶	۲۰	R1	۷۸/۰۹۶۱	۸/۸۳۷۲	
۷	۲۲	R1	۱۱۲/۷۰۷۹	۱۰/۶۱۶۴	
۸	۲۴	R1	۸۷/۹۶۹۴	۹/۳۷۹۲	
۹	۲۶	R1	۷۵/۹۲۶۸	۸/۷۱۴۶	
۱۰	۲۸	R1	۹۲/۶۰۹۸	۹/۶۲۳۴	
۱۱	۳۰	R1	۶۳/۴۶۱۹	۷/۹۶۶۳	

جدول ۹. عملکرد نمونه‌ها در شبکه LSTM با الگوریتم آموزشی Sgdm


Table 9. Performance of samples in Lstm network with Sgdm training algorithm

ویژگی‌ها	تعداد نمونه‌ها	ارزیابی (عملکرد)	الگوریتم آموزشی
۱۴	۳۲۰	Root Mean Squared Error	Sgdm
ماکزیمم تکرار	تعداد	تعداد	داده‌های آموزش
۲۵۰	۶۵	(%)	(%)
		۲۰	۲۵۶
		۸۰	
ردیف	تعداد نورون‌های لایه پنهان	MSE	RMSE
۱	۱۰	۸۸/۶۲۷۱	۹/۴۱۴۲
۲	۱۲	۷۴/۹۹۰۰	۸/۶۵۹۷
۳	۱۴	۸۶/۶۱۸۳	۹/۳۰۶۴
۴	۱۶	۷۲/۷۴۲۱	۸/۵۲۸۹
۵	۱۸	۵۱/۶۲۴۲	۷/۱۸۵۰
۶	۲۰	۱۰۱/۹۴۳۳	۱۰/۰۹۶۷
۷	۲۲	۱۸۴/۵۱۴۱	۱۳/۵۸۳۶
۸	۲۴	۵۹/۴۳۴۸	۷/۷۰۹۴
۹	۲۶	۶۵/۵۶۳۰	۸/۰۹۷۱
۱۰	۲۸	۷۲/۷۵۲۳	۸/۵۲۹۵
۱۱	۳۰	۶۵/۳۳۹۷	۸/۰۸۳۳

جدول ۱۰. مقایسه عملکرد الگوریتم‌های شبکه LSTM

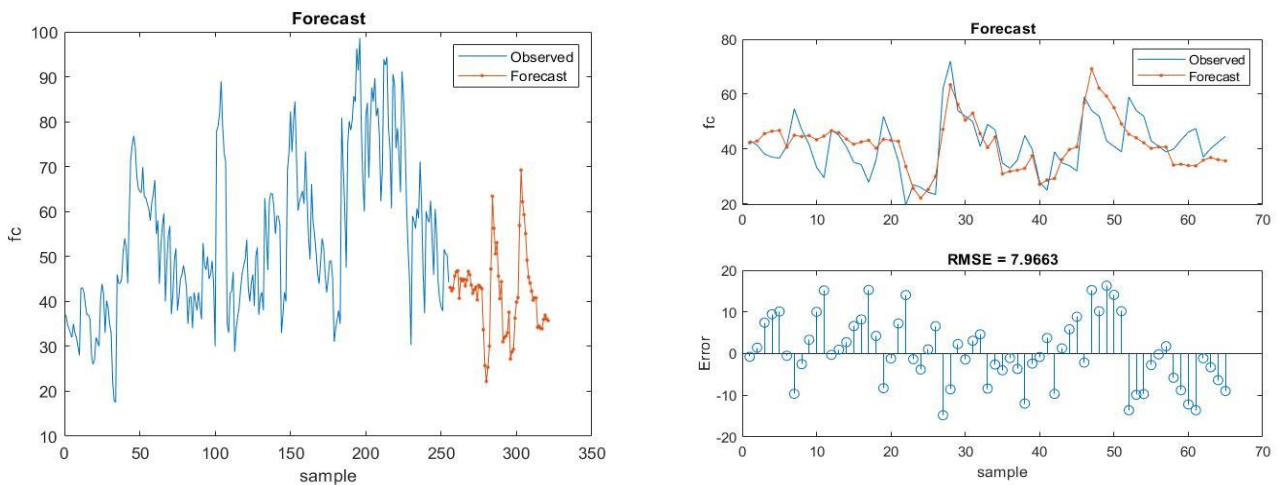
Table 10. Comparison of the performance of Lstm network algorithms 1.

الگوریتم آموزشی	عملکرد شبکه با بهترین ساختار معماری
	در هر الگوریتم آموزشی
	RMSE
Adam	۱۰/۰۸۵۶
Rmsprop	۷/۹۶۶۳
Sgdm	۷/۱۸۵۰



شکل ۱۱. نمودار روند آموزش و خطای شبکه LSTM با استفاده از الگوریتم آموزش Adam

Fig. 11. Diagram of training process and LSTM network error using Adam training algorithm

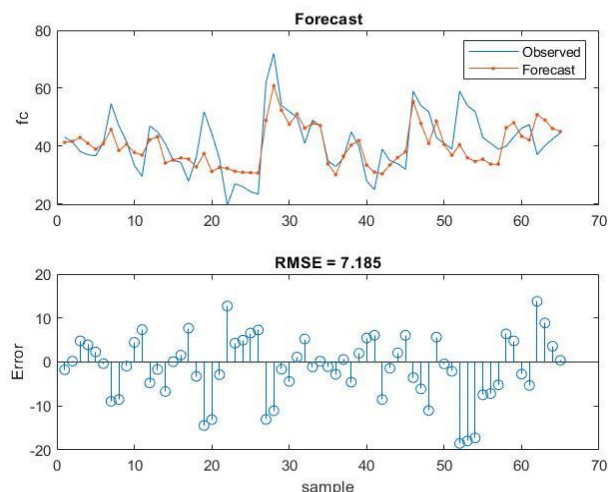
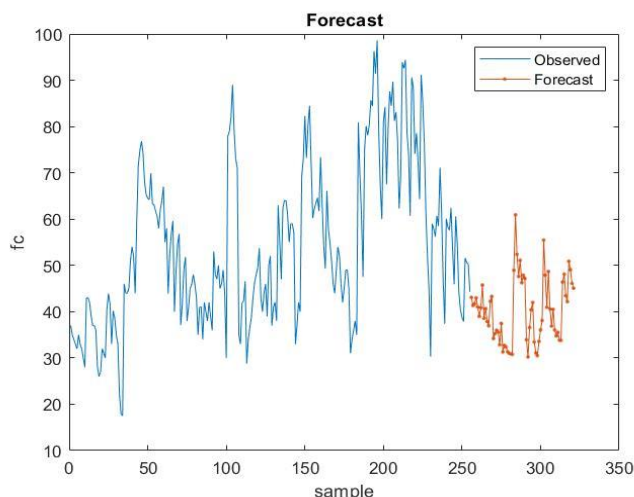


شکل ۱۲. نمودار روند آموزش و خطای شبکه LSTM با استفاده از الگوریتم آموزش Rmsprop

Fig. 12. Diagram of training process and LSTM network error using Rmsprop training algorithm

همانطور که از جدول‌های ۸ و ۹ مشخص است، بهترین عملکرد با توجه به توضیحات پیشین، مربوط به ردیف ۱۱ از جدول ۸ با ریشه میانگین مربعات خطای ۷/۹۶۶۳ و ردیف ۵ از جدول ۹ با ریشه میانگین مربعات خطای ۷/۱۸۵۰ می‌باشد، که به ترتیب دارای ۳۰ نورون و ۱۸ نورون در لایه میانی می‌باشد. نمودار عملکرد شبکه LSTM با الگوریتم‌ها آموزشی مذکور را می‌توان در شکل‌های ۱۱ تا ۱۳ مشاهده کرد.

خواهیم دید بهترین عملکرد در شرایط یکسان مربوط به الگوریتم Sgdm خواهد بود. مقدار ریشه مربعات خطای ۷/۱۸۵۰ و ۱۸ نورون در لایه میانی می‌باشد. نمودار عملکرد شبکه LSTM با الگوریتم‌ها آموزشی مذکور را می‌توان در شکل‌های ۱۱ تا ۱۳ مشاهده کرد.



شکل ۱۳. نمودار روند آموزش و خطای شبکه LSTM با استفاده از الگوریتم آموزشی Sgdm

Fig. 13. Diagram of training process and LSTM network error using Sgdm training algorithm

Gradient زمان کمتری صرف کرده و به تبع دقت کمتری هم دارد. اگر چه با توجه با جدیدتر بودن شبکه عصبی LSTM نسبت به ANN انتظار می‌رفت نتایج شبکه LSTM بهتر شود، اما باید توجه داشت، اختلاف بین دو شبکه بسیار ناچیز بوده و صرفاً در این مسئله خاص (پیش‌بینی مقاومت فشاری ۲۸ روزه) نتیجه شبکه ANN بهتر شده و در صورت تغییر مسئله، نتایج می‌تواند متفاوت باشد.

یکی از دلایلی که باعث می‌شود نتایج شبکه در تکرارهای مختلف، بین شبکه LSTM و ANN متفاوت باشد، تصادفی انتخاب کردن نمونه‌ها می‌باشد. در شبکه ANN انتخاب داده‌ها به جهت تست و آموزش در تکرارهای مختلف متفاوت که نتایج متفاوت در بر خواهد داشت، حال آن که در شبکه LSTM با ماهیت سری زمانی، داده‌ها به صورت یکسان از آخرین داده‌های ورودی انتخاب می‌شود، لذا نتایج می‌تواند بین دو شبکه متفاوت باشد.

اختلاف اعداد گزارش شده در هر ۶ الگوریتم آموزشی بعضاً بسیار ناچیز بوده است، اما عملکرد شبکه با کمترین خطا مدنظر می‌باشد، لذا با توجه به عمومیت شبکه از نظر مصالح تعریف شده در نمونه‌های بتن خودتراکم، انتظار می‌رود با ورود طرح اختلاط جدید، شبکه با کمترین خطا مقاومت فشاری ۲۸ روز را پیش‌بینی کند.

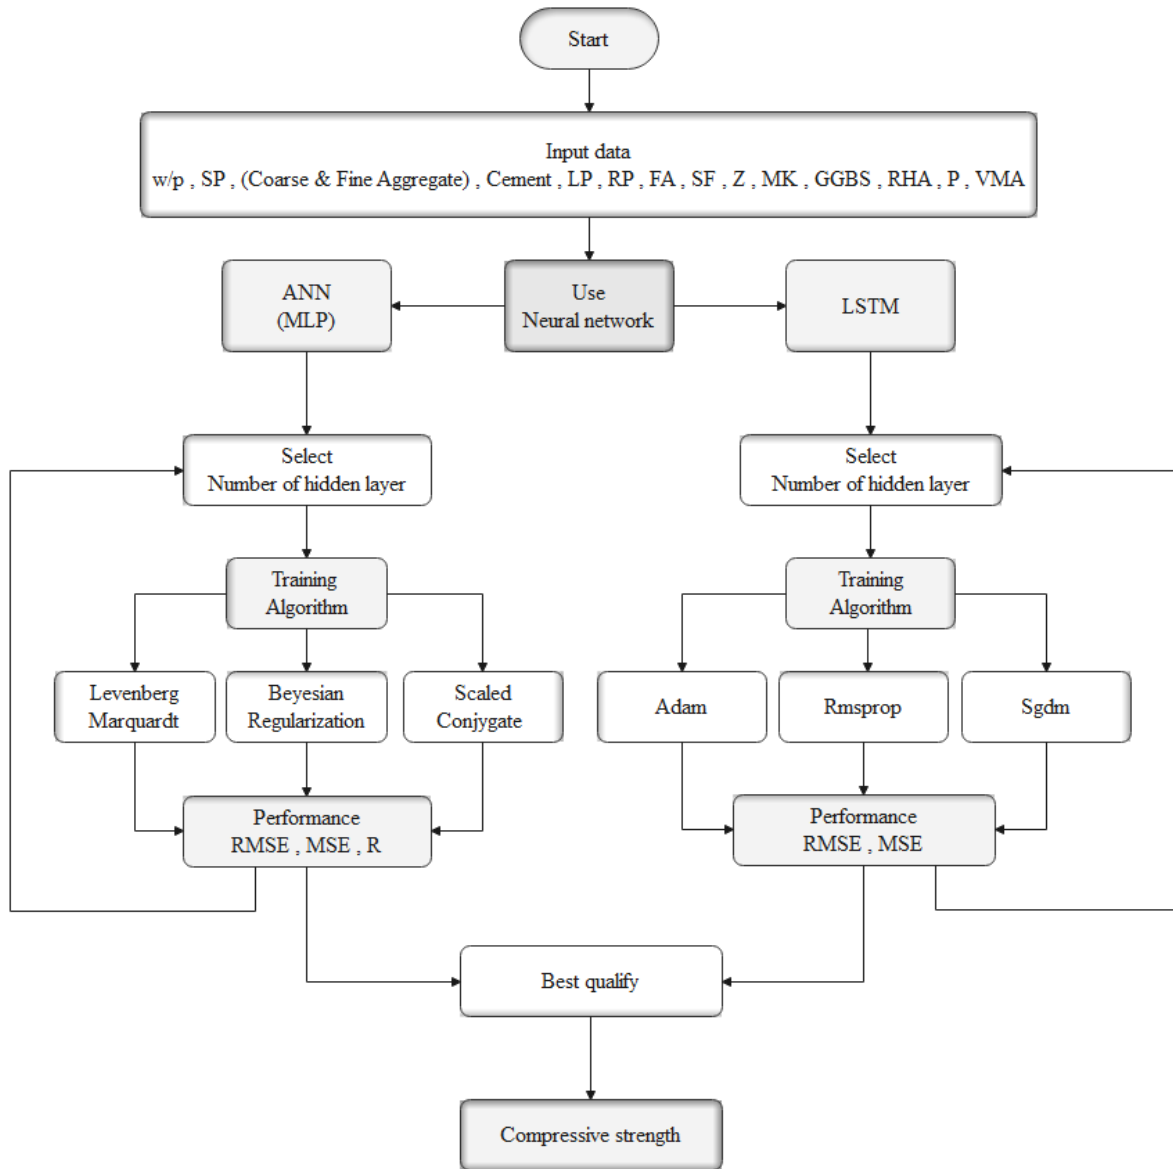
ملاک تقسیم داده‌های آموزش و آزمایش در این پژوهش، میزان فراوانی داده‌ها بوده است. اگر چه میزان داده‌ها (۳۲۰ نمونه) از نظر فراوانی مطلوب

حال اگر بخواهیم بهترین حالت شبکه LSTM را با شبکه ANN با توجه به مسیری که تا به اینجا طی کردیم (شکل ۱۴) در این مسئله خاص مورد مقایسه قرار دهیم، عملکرد الگوریتم آموزشی Bayesian Regularization در شبکه ANN از الگوریتم Sgdm در شبکه LSTM صرفاً با توجه به شاخص RMSE، بهتر خواهد بود، همچنین لازم به ذکر است، این به معنی نفی شبکه LSTM و سایر الگوریتم‌های آموزشی نبوده و صرفاً در این مسئله خاص این نتیجه حاصل شده است (جدول ۱۱).

۵- نتیجه‌گیری

اگر چه نتیجه شبکه ANN با الگوریتم آموزشی Bayesian Regularization نسبت به دو الگوریتم آموزشی دیگر در این شبکه (Scaled Conjugate Gradient و enberg Marquardt) بهتر شده است، اما این به این معنی نیست که با دو الگوریتم آموزشی دیگر نتوان عمل پیش‌بینی را انجام داد، بلکه صرفاً دقت پیش‌بینی در طی آموزش با دو الگوریتم آموزشی دیگر کمتر است، که حتی در این مسئله خاص، اختلاف ناچیز بوده است.

آموزش شبکه عصبی با الگوریتم آموزشی Bayesian Regularization نسبت به دو الگوریتم آموزشی دیگر زمان بیشتری برده و هر چی داده‌ها و ویژگی‌های هر ورودی بیشتر باشد، زمان آموزش در راستای اصلاح اوزان افزایش می‌یابد، از طرفی الگوریتم آموزشی Scaled Conjugate



شکل ۱۴. فلوچارت عملکرد شبکه عصبی ANN و LSTM

Fig. 14. Flowchart of ANN and LSTM neural network function

جدول ۱۱. مقایسه عملکرد دو شبکه ANN و LSTM

Table 11. Comparison of ANN and LSTM network performance

شبکه عصبی	الگوریتم آموزشی	RMSE آزمایش
ANN	Bayesian Regularization	۴/۹۷۰۰
LSTM	Sgdm	۷/۱۸۵۰

- [9] J. Xiao, Z. Ma, T. Sui, A. Akbarnezhad, Z. Duan, Mechanical properties of concrete mixed with recycled powder produced from construction and demolition waste. *Journal of Cleaner Production*, 188 (2018) 720-731.
- [10] A. Majumdar, A. Mitra, D. Banerjee, P.K. Majumdar, Soft computing applications in fabrics and clothing: a comprehensive review. *Research Journal of Textile and Apparel*, (2010).
- [11] S. Selvaraj, S. Sivaraman, Prediction model for optimized self-compacting concrete with fly ash using response surface method based on fuzzy classification. *Neural Computing and Applications*, 31(5) (2019) 1365-1373.
- [12] A. Iqtidar, N. Bahadurkhan, S. Kashif-ur-Rehman, M. Faisal Javed, F. Aslam, R. Alyousef, H. Alabduljabbar, A. Mosavi, Prediction of compressive strength of rice husk ash concrete through different machine learning processes. *Crystals*, 11(4) (2021) 352.
- [13] M. Serraye, S. Kenai, B. Boukhatem, Prediction of compressive strength of self-compacting concrete (SCC) with silica fume using neural networks models. *Civil Engineering Journal*, 7(1) (2021) 118-139.
- [14] S. Hochreiter, J. Schmidhuber, Long short-term memory. *Neural computation*, 9(8) (1997) 1735-1780.
- [15] F.A. Gers, J. Schmidhuber, Recurrent nets that time and count. in *Proceedings of the IEEE-INNS-ENNS International Joint Conference on Neural Networks. IJCNN 2000. Neural Computing: New Challenges and Perspectives for the New Millennium*. (2000).
- [16] S.M. Davoodnabi, M. Safehian, The effect of using mineral additives (silica fume, zeolite, slag, limestone powder) on the compressive strength and surface electrical resistance of self-compacting concrete considering the fixed paste volume. *3rd International Conference on Applied Researches in structural engineering and construction management*, (2019) (in Persian).
- [17] M.S. Abasifar, M.R. Pirmohammadi, S.M. Mirhoseini, S.H. Pirmohammadi, The effect of replacing limestone powder with recycled travertine stone powder on

می‌باشد، اما هر روز در جهان بتن‌های خودتراکمی ساخته می‌شود که قابلیت اضافه شدن به شبکه را در جهت افزایش دامنه اطلاعات شبکه و پیش‌بینی دقیق‌تر (درصد خطای کمتر) را دارد، لذا با توجه به آزمون خطاهای انجام گرفته، تصمیم بر این شد بخش عمده داده‌ها برای آموزش و حدوداً ۲۰ درصد داده‌ها را برای آزمایش و اعتبارسنجی قرار دهیم.

منابع

- [1] H. Okamura, M. Ouchi, Self-compacting concrete—*Journal of Advanced Concrete Technology*, vol. 1. (2003).
- [2] EFNARC, *Guidelines for Self-Compacting Concrete*, European Federation for Specialist Construction Chemicals and Concrete Systems, Norfolk, UK. English ed., February, (2002).
- [3] M.F. Granata, Pumice powder as filler of self-compacting concrete. *Construction and Building Materials*, 96 (2015) 581-590.
- [4] F.A. Mustapha, A. Sulaiman, R.N. Mohamed, S.A. Umara, The effect of fly ash and silica fume on self-compacting high-performance concrete. *Materials Today: Proceedings*, 39 (2021) 965-969.
- [5] F. Pirmohammadi Alishah, The Effect of Zeolite on Different Mechanical Properties and Permeability of Self-Compacting Concrete. *Computational Engineering and Physical Modeling*, 3(1) (2020) 53-68.
- [6] J. Seelapureddy, J. Bommisetty, M.V. Seshagiri Rao, Effect of metakaolin and micro silica on strength characteristics of standard grades of self-compacting concrete. *Materials Today: Proceedings*, 45 (2021) 884-890.
- [7] E.M. Raisi, J.V. Amiri, M.R. Davoodi, Mechanical performance of self-compacting concrete incorporating rice husk ash. *Construction and Building Materials*, 177 (2018) 148-157.
- [8] A.A.A. Al-Oran, N.A. Safiee, N.A. Mohd Nasir, Fresh and hardened properties of self-compacting concrete using metakaolin and GGBS as cement replacement. *European Journal of Environmental and Civil Engineering*, (2019) 1-14.

- [25] P.S. Pourhosein, Investigation of physical properties of self-compacting concrete containing different ratios of water to cement. International conference on the new horizons in the basic and technical sciences and engineering, Tehran, (2017) (in Persian).
- [26] E. Nassirnia, S. Rahimi, S.Y. Mousavi, The effect of pozzolan pumice on the properties of fresh and hardened self-compacting concrete. A Thesis Presented for the Degree of Master of science In Civil Engineering-Structure. Allameh Mohaddes Nouri University, Nour, iran, (2016) (in Persian).
- [27] A. Meshkini, F. Pirmohammadi alishah, Properties of lightweight self-compacting concrete containing pumice as a cement substitute. 3rd International conference on science and engineering, Istanbul, Turkey, (2016) (in Persian).
- [28] A.A. Hassan, M.K. Ismail, J. Mayo, Mechanical properties of self-consolidating concrete containing lightweight recycled aggregate in different mixture compositions. Journal of Building Engineering, 4 (2015) 113-126.
- [29] H. Nouripahlevanlou, J. Berenjian, M. Hoseinalibeygi, O. Lotfi Omran, S. Jalilian, Laboratory study of engineering properties and stability of self-compacting concrete containing methacoline pozzolan. 7th National concrete Conference of iran, Tehran, (2015) (in Persian).
- [30] A. Eftekhari, V. Naderi, A. Foroughi Asl, Impact of microsilica on the mechanical properties and permeability of self-compacting concrete. 9th National concrete Conference of iran, Tehran, (2015) (in Persian).
- [31] H. Varastepour, J. Morovati, S.V. Aghebatkhah, Investigation of the effects of VMA and limestone powder composition on the properties of fresh and hardened self-compacting concrete. International conference on science and engineering, Dubai, UAE, (2015) (in Persian).
- [32] J. Berenjian, H. Nouri pahlevanloo, The effect of rice husk ash pozzolan replacement on the mechanical properties of self-compacting concrete. 2nd International congress on structure, architecture & urban development, Tabriz, (2014) (in Persian).
- compressive strength and volume water absorption in self-compacting concretes. 11th National Conference on concrete, Tehran, (2019) (in Persian).
- [18] E. Varjavand, M. Sobhaninia, The effect of rice husk ash and sugarcane pulp on the compressive strength of self-compacting concrete. 3rd Conference on Engineering Sciences, Kish Island, (2019) (in Persian).
- [19] M. Khanzadi, M.R. Nabizadeh, S.R. Bagheri, V. Ghalenoei, Investigation of the effect of zeolite and mesbar on the performance of self-compacting concrete. First National Concrete Industry Conference, Kerman, (2012) (in Persian).
- [20] A. Khani, M. Tadion, M.E. Komaki, S.M. Sajad Atar, Investigation and evaluation of K factor in self-compacting concretes containing zeolite and smelting furnace slag. 9th National Conference on concrete, Tehran, (2017) (in Persian).
- [21] P. Ghoddousi, A.A. Shirzad Javid, S.H. Hoseini Rostami, B. Mehri, Rheology study of self-compacting concretes containing mineral additives. 5th National Conference on Self-Consolidating concrete and 1st National Conference on Repair and Maintenance of concrete structures, Tehran, (2017) (in Persian).
- [22] P. Razmara, S. Saidijam, J. Afiati, Self-compacting concrete: Green concrete technology with an attitude towards the environment. The 4th International Conference on Environmental planning and Management, Tehran, (2017) (in Persian).
- [23] M.S. Hoseini, H. Varastepour, Investigation of the effects of water to cement ratio on the properties of self-compacting concrete and its optimization with VMA and lime powder. 4th International Conference on Advanced Technology in Civil engineering, Architecture and Urban planning, Tehran, (2017) (in Persian).
- [24] M.H. Khazali, A.R. Nikkhah, D. Rahimi, Investigation of the effect of zeolite, microsilica, slag and lime powder on the mechanical properties of self-compacting concrete. 9th National Conference on concrete, Tehran, (2017) (in Persian).

- [39] A. Sadrmomtazi, M.A. Ahmadi Rad, H. Rostami Atigh, Evaluation of flexural compressive strength and modulus of elasticity of SCC self-compacting concrete containing rice paddy husk ash. National congress of self-compacting concrete(NCSCC), Kerman, (2011) (in Persian).
- [40] O. Farshadfar, K. Behfarnia, D. Mostofinejad, Investigation of the effect of pozzolan types on mechanical properties of fiber self-compacting concrete. 6th National Congress of Civil Engineering, Semnan, (2011) (in Persian).
- [41] A. Askari, M.R. Sohrabi, Y. Rahmani, M. Mehravaran, The effect of nanosilica on the mechanical properties of self-compacting concrete containing fly ash. 6th National Congress of Civil Engineering, Semnan, (2011) (in Persian).
- [42] E. Güneyisi, M. Gesoglu, E. Özbay, Evaluating and forecasting the initial and final setting times of self-compacting concretes containing mineral admixtures by neural network. *Materials and structures*, 42(4) (2009) 469-484.
- [43] L. Smith, R. German, M. Smith, A neural network approach for solution of the inverse problem for selection of powder metallurgy materials. *Journal of Materials processing technology*, 120(1-3) (2002) 419-425.
- [44] S. Lek, M. Delacoste, Ph. Baran, L. Lauga, S. Aulagnier, Application of neural networks to modelling nonlinear relationships in ecology. *Ecological modelling*, 90(1) (1996) 39-52.
- [33] M. Ghasemi, J. Berenjjan, H. Azari Jafari, N.R. Forouhar, The effect of natural zeolite and Taftan pumice replacement on the characteristics of fresh and hardened self-compacting concrete. 5th National concrete Conference of iran, Tehran, (2013) (in Persian).
- [34] H. Aslani, Z. Khazemi, A. Aslani, Self-compacting concrete mixing scheme without the use of viscosity modifiers. National Conference on Applied Civil Engineering and New Achievements, Karaj, (2014) (in Persian).
- [35] M.S. Sargazi Moghdam, M.H. Mirabi Moghadam, S. Rahat Dehmardeh, Influence of superplasticizer rate on rheological, mechanical and porosity properties of self-compacting concrete. 2nd National conference on material and new structures, Esfahan, (2014) (in Persian).
- [36] T. Khazaeni, M. Miri, N. Sarani, Investigation of durability and mechanical properties of self-compacting concrete containing metakaolin and pumice. 5th National concrete Conference of iran, Tehran, (2013) (in Persian).
- [37] R. Madandoust, S.Y. Mousavi, Fresh and hardened properties of self-compacting concrete containing metakaolin. *Construction and building materials*, 35 (2012) 752-760.
- [38] M.M. Ranjbar, R. Madandoust, F. Ghane, S. Esapour, M. Karimi, Evaluation of engineering properties of potent self-compacting concrete containing pozzolans. 4th National concrete Conference of iran, Tehran, (2012) (in Persian).

چگونه به این مقاله ارجاع دهیم

S. M Masrouri Saadat, E. Jahani, Prediction of compressive strength of self-compacting concrete containing different fillers with the help of Artificial Neural Networks, *Amirkabir J. Civil Eng.*, 54(10) (2023) 3835-3856.

DOI: 10.22060/ceej.2022.20488.7438

