

ИЗКУСТВЕНИ НЕВРОННИ МРЕЖИ ЗА ПРОГНОЗИРАНЕ НА ИНДЕКСИ НА ПРОИЗВОДИТЕЛНОСТТА НА КОМУНИКАЦИОННИТЕ КАНАЛИ

Ивелина Балабанова

*Технически университет - Габрово, ул. „Хаджи Димитър“ № 4, Габрово, България,
Кореспондиращ автор: ivstoeva@abv.bg*

ARTIFICIAL NEURAL NETWORKS FOR PERFORMANCE INDICES FORECASTING OF COMMUNICATION CHANNELS

Ivelina Balabanova

*Technical University of Gabrovo, 4 Str. "Hadj Dimitar", Gabrovo, Bulgaria,
* Corresponding author: ivstoeva@abv.bg*

Abstract

The paper proposes an approach for predictive analysis of performance indices during traffic transmission and service in information and communication channels with Artificial Intelligence (AI) concept. Radial Basis Neural Networks (RBNNs) and Feed-Forward Neural Networks (FFNNs) in a change of the Spread parameter and the type of neural activation – Hyperbolic tangent and Logarithmic Sigmoid, in the radial-basis and output layers of the networks are applied. Training and verification procedures of the specified neural structures for the approximation of System Throughput (ST) and System Response Time (SRT) indices against the Service Demand (SD) traffic factor were conducted. The performance evaluation of RBNNs and FFNNs is based on a set of criteria consisting of Mean Squared Error (MSE), Mean Absolute Error (MAE), Root Mean Square Error (RMSE), Variance, etc. The Radial Basis and Feed-Forward models assumed with minimization found for the specified criteria and a high correlation between the Observed and Predicted values about ST and SRT incoming traffic indices are synthesized.

Keywords: ICT technologies; performance prediction; QoS; radial basis; feed-forward.

1. ВЪВЕДЕНИЕ

Ефективността на обслужване на пакетни данни в информационно-комуникационните системи SD е комплексен процес, основаващ се на редица фактори и параметри на преносната среда и използваните комуникационни канали за връзка. Съществени индикатори, свързани с тези процедури са „пропускателната способност ST“ и „общото време за чакане на обслужване и обработка на потребителски заявки SRT“. Поддържането на оптимално съотношение между посочените индекси попада в обхвата на всяка ИКТ структура, независимо от сложността на организация на информационния мониторинг и администриране [1-3]. Това изискване може да бъде по-

стигнато чрез интеграцията на аналитични инструменти за прогнозен анализ, позволяващи изчисляване на „очакван количествен еквивалент“ на ST и SRT. Наличието на тези прогнозни количествени оценки ще даде възможност за повишаване на бързодействието и надеждността при обслужване на системните потребители на ICTs. Проблемът е особено актуален в редица сектори на комуникациите като 5G; LTE; Wireless, Cellular, High-Speed, Mobile Edge Networks; Internet; IoT и др. В качеството на инструменти за статистическо моделиране в подобни изследвания служат Long Short-Term Memory, Recurrent Units, Adaptive-Neuro Fuzzy Interface Systems, Gaussian Process Regression,

Convolutional Neural Networks и други [4-9].

Обект на изследване в настоящия доклад е моделирана ICT инфраструктура с опашкова организация на обработката на заявки при дефиниран набор от сървърни звена за първична и вторична манипулация с данните чрез Java Modeling Tool платформа. Основната задача тук се свързва със синтез на модели на основата на AI за прогнозиране на указваните:


- ❖ System Throughput;
- ❖ System Response Time;

индекси относно входящия постъпващ трафик на етап планиране с оглед на изграждане и експлоатация. Въведен е хибриден подход с включване Radial Basis Neural Networks и Feed-Forward Neural Networks при декларираните управляеми фактори:

- ❖ Service Demand;
- ❖ Service Demand².

2. ОБУЧЕНИЕ И СЕЛЕКЦИЯ НА RADIAL BASIS NEURAL NETWORKS

В рамките на първа фаза от анализа е направено обучение и оценка на ефективността на Radial Basis Neural Networks. Заложените невронни модели са изградени от входен, скрит радиално-базисен и изходен слой с линейна активационна функция. Особеност на този вид мрежи е общата фаза на създаване и невронно обучение. В структурно отношение количеството на изчислителните неврони във втория слой на RBNNs остава непроменен независимо от увеличаването или намаляването на „широчината на функцията – Spread Indicator (SI)“. Броят на радиално базисните скрити неврони автоматично се приравнява на фиксираното количество на еталоните в подавания към мрежите входен набор, показано на фиг. 1. В таблица 1 са дадени резултатите за изходните показатели при оценка на качеството на RBNNs – MSE, MAE и RMSE, едновременно обобщени за ST и STR.



Фиг. 1. RBNN за прогнозен анализ на индекси на производителност ST и STR

Табл. 1. RBNN при прогнозиране на изменението на индекси на производителност ST и STR при две входни променливи

SI	MSE	MAE	RMSE
System Throughput			
0.10	7.7309e-12	2.0281e-06	2.7805e-06
0.15	2.3484e-11	4.0773e-06	4.8460e-06
0.20	5.9231e-11	6.0761e-06	7.6962e-06
0.25	6.4694e-11	6.2573e-06	8.0433e-06
0.30	7.1730e-11	7.0615e-06	8.4693e-06
0.35	7.7241e-11	7.3046e-06	8.7887e-06
0.40	8.1960e-11	7.7676e-06	9.0532e-06
0.45	8.1520e-11	7.7370e-06	9.0288e-06
0.50	8.4402e-11	7.9536e-06	9.1870e-06
0.55	8.4309e-11	7.9503e-06	9.1820e-06
0.60	8.4188e-11	7.9454e-06	9.1754e-06
0.65	8.6694e-11	8.0451e-06	9.3110e-06
0.70	8.8591e-11	8.1885e-06	9.4123e-06
0.75	8.8577e-11	8.1878e-06	9.4115e-06
0.80	8.8570e-11	8.1875e-06	9.4112e-06
0.85	8.8576e-11	8.1883e-06	9.4115e-06
0.90	8.8721e-11	8.1890e-06	9.4192e-06
System Response Time			
0.10	2.2659e-16	1.0985e-08	1.5053e-08
0.15	7.0014e-16	2.2364e-08	2.6460e-08
0.20	1.7846e-15	3.3327e-08	4.2245e-08
0.25	1.7846e-15	3.3327e-08	4.2245e-08
0.30	2.1609e-15	3.8694e-08	4.6485e-08
0.35	2.3329e-15	4.0039e-08	4.8300e-08
0.40	2.4844e-15	4.2629e-08	4.9844e-08
0.45	2.4698e-15	4.2454e-08	4.9697e-08
0.50	2.5663e-15	4.3712e-08	5.0659e-08
0.55	2.5637e-15	4.3698e-08	5.0633e-08
0.60	2.5581e-15	4.3630e-08	5.0578e-08
0.65	2.6415e-15	4.4207e-08	5.1396e-08
0.70	2.7021e-15	4.5046e-08	5.1981e-08
0.75	2.7017e-15	4.5041e-08	5.1978e-08
0.80	2.7010e-15	4.5034e-08	5.1971e-08
0.85	2.7006e-15	4.5010e-08	5.1968e-08
0.90	2.7064e-15	4.5021e-08	5.2023e-08

Проведеният анализ на поведението на указваните критерии обхваща RBNNs при стъпково нарастване на SI в диапазона 0.1 – 0.9. Установени са удовлетворяващи целите на изследването степени:

- ❖ „10⁻¹¹“ за средноквадратичната и „10⁻⁶“ при средната абсолютна грешка и средното квадратично отклонение;

- ❖ „ 10^{-15} “ при MSE и „ 10^{-8} “ за MAE и RMSE;

на приложените входни данни при обучаващите процедури. Регистрираните стойности на MSE, MAE и RMSE се характеризират с експоненциално нарастване до нива на $SI = 0.4$. Наблюдавано е известно установяване на количествени критерии с вариращи колебания:

- ❖ „ $8.1400 \cdot 10^{-11}$ до $8.9000 \cdot 10^{-11}$ “ при MSE, „ $7.7000 \cdot 10^{-6}$ до $8.2000 \cdot 10^{-6}$ “ за MAE и „ $9.0000 \cdot 10^{-6}$ до $9.4200 \cdot 10^{-6}$ “ относно RMSE при невронен подбор за ST;
- ❖ „ $2.5600 \cdot 10^{-15}$ до $2.7100 \cdot 10^{-15}$ “ относно MSE, „ $4.3500 \cdot 10^{-8}$ до $4.5100 \cdot 10^{-8}$ “ за MAE и „ $5.0000 \cdot 10^{-8}$ до $5.2100 \cdot 10^{-8}$ “ относно RMSE при избор на прогнозен модел за SRT;

до крайна широчина на радиално базисната функция $SI = 0.9$. Вследствие на извършените дейности са селектирани RBNN архитектури за прогнозиране на трафични индекси на производителност ST и SRT при минимална заложена широчина на радиално базисната функция $SI = 0.1$, в случайте на постигане на $MSE = 7.7309 \cdot 10^{-12}$ и $MSE = 2.2659 \cdot 10^{-16}$.

3. СИНТЕЗ И ВЕРИФИКАЦИЯ НА FEED-FORWARD НЕВРОННИ СТРУКТУРИ

Втората фаза от реализираните изследвания се свежда до анализ на ефективността на Feed-Forward Neural Networks за прогнозен анализ на ST и SRT. За FFNNs са характерни отделни процеси на създаване и обучение по Levenberg-Marquardt градиентен алгоритъм, както и константна тангес-сигмоидална активация tansig във втория структурен слой. При невронен синтез е разгледана и анализирана приложимостта два варианта на активация в изходния слой на мрежите, т.е. последователно използване на логаритмична-сигмоидална logsig и tansig функция. Процедурите са проведени при еднаква вириация на скритите неврони HN, ограничена от 3 до 13 изчислителни единици.


Таблица 2 съдържа сметните стойности на идентичните критерии за оценка на качеството MSE, MAE и RMSE за трафичен индекс ST. В хода на изследванията са констатирани значително завишени нива на базисните фактори за невронен подбор при използване на logsig активационен тип, в пъти по-големи в сравнение с RBNNs.

Табл. 2. FFNN при прогнозен анализ на индекс ST при logsig и tansig изходна активация


HN	MSE	MAE	RMSE
Logsig изходна активация			
3	0.1516	0.2269	0.3894
4		0.2238	0.3893
5	0.1567	0.2661	0.3958
6	0.1515	0.2231	0.3893
7	0.1516	0.2259	0.3894
8	0.1515	0.2233	
9	0.1516	0.2232	
10	0.1515	0.2225	0.3893
11	0.1516	0.2239	
12	0.1515	0.2221	
13	0.1515	0.2234	
Tansig изходна активация			
3	0.0081	0.0682	0.0898
4	0.0054	0.0588	0.0733
5	0.0082	0.0563	0.0904
6	0.0178	0.0958	0.1334
7	0.0078	0.0662	0.0882
8	0.0149	0.1009	0.1220
9	0.0018	0.0354	0.0422
10	0.0095	0.0751	0.0976
11	0.0012	0.0296	0.0340
12	0.0045	0.0527	0.0668
13	0.0028	0.0389	0.0530

Отчетените грешки остават сравнително близки в цялостния диапазон, независимо от увеличаването на невроните в скрития слой. Относно модел за прогнозен анализ на „пропускателната способност“ е селектирана архитектура с получени $MSE = 0.015$, $MAE = 0.2221$ и $RMSE = 0.3893$, представена на фиг. 2.а). Посредством замаяната на типа на изходна активация при FFNNs се постигна значително подобряване на качествените показатели. Тук тяхната минимизация е сведена до нива 0.0012 при MSE, 0.0296 за MAE и 0.0340 относно RMSE, регистрирани на намерен най-подходящ невронен модел за прогнозен анализ със съдържание на 11 скрити неврона на фиг. 2.б). Максимална средно квадратична грешка 0.0081, средна абсолютна грешка

0.0682 и средно квадратично отклонение 0.0898 са установени при FFNN при начален зададен брой неврони в скрития слой.



a)



б)


Фиг. 2. Синтезирани FFNNs за прогнозиране на ST с а) Logsig и б) Tansig изходни функции

Различията във функционалността на синтезираните невронни модели са допълнително илюстрирани чрез линиите на регресия за мрежовите изходи на фиг. 3 и диаграмите на грешките на фиг. 4. Залагането на логаритмично-сигмоидална активация в изходния слой се свързва с:


- ❖ постигане на коефициент на корелация $R = 0.90464$ и забележимо отклонение на емпиричната спрямо теоретичната линия на регресия, предизвикващи подобно явление относно обхванатите информационни еталони;
- ❖ наличие на известна част от еталони от информационната извадка с голяма разлика между теоретичните и прогнозните нива на трафичен индекс ST, превишаващи приемливото за друга част от извадката ниво „-0.02000“.

Използването на тангенс-сигмоидална изходна функция притежава силно положителен ефект, изразяващ се в констатирана превишаваща logsig корелация $R = 0.99839$. Също така и минимални Residuals в приемливи граници на отклонение на Predicted в сравнение с

Observed стойности на разглеждания ICT трафичен индекс ST.




a)




б)

Фиг. 3. Линии на регресия за селектираните FFNNs за прогнозен анализ на ST с а) Logsig и б) Tansig изходни функции

Използването на тангенс-сигмоидална изходна функция притежава силно положителен ефект, изразяващ се в констатирана превишаваща logsig корелация $R = 0.99839$. Също така и минимални Residuals.



a)



б)

Фиг. 4. Хистограми на грешките за избраните крайни FFNNs за прогнозиране на ST с а) Logsig и б) Tansig изходни функции


По отношение на втория целеви индекс на производителност са констатирани процедури по минимизация на MSE, MAE и RMSE (таблица 3). Ясно изразено е подобряването на посочените показатели, особено относно пригодността на logsig изходен тип на активация. Факт е регистрираният порядък за средноквадратичната грешка „10⁻⁶“ при търсене на най-подходящ модел за индекс ST. Запазва се тенденцията за минимални изменения на MSE и поява на възникнала липса на изменение на RMSE при нарастване на количеството на изчислителните единици в скритите слоеве на мрежите.

В качеството на краен прогнозен модел е избрана FFNN със съдържание на 10 междинни неврона при постигнати MSE = 6.7014⁻⁶, MAE = 0.0017 и RMSE = 0.026 на фиг. 5.а). Съществено е подобрието на критериите за количествен анализ при задаване на тангенсигмоидална изходна функция на активация за трафикен индекс SRT в сравнение с изходните резултати при подбор на FFNNs за ST. Тук постигнатите нива се доближават до ефективността на Radial Basis Neural Networks. Получени са най-високи стойности на MSE = 3.2301⁻⁸, MAE = 1.2424⁻⁴ и RMSE = 1.7972⁻⁴ при невронна структура с 5 междинни неврона.

Табл. 3. FFNN при прогнозиране на индекс на производителност на SRT при logsig и tansig изходна функции

HN	MSE	MAE	RMSE
Logsig изходна активация			
3	6.7039e-06	0.0017	0.0026
4	6.7453e-06	0.0018	
5	6.7098e-06		
6	6.7073e-06		
7	6.7188e-06		
8	6.7086e-06		
9	6.7024e-06	0.0017	
10	6.7014e-06	0.0018	
11	6.7377e-06		
12	6.7069e-06		
13	6.7171e-06		
Tansig изходна активация			
3	6.3586e-09	4.4472e-05	7.9741e-05
4	2.3862e-08	1.0029e-04	1.5447e-04
5	3.2301e-08	1.2424e-04	1.7972e-04
6	1.5496e-09	2.4740e-05	3.9365e-05
7	1.8582e-09	2.5191e-05	4.3107e-05
8	6.4455e-09	4.7123e-05	8.0284e-05
9	1.9885e-08	7.9292e-04	1.4101e-04
10	2.2955e-09	3.0967e-05	4.7912e-05
11	1.9759e-09	2.3942e-05	4.4451e-05
12	3.5390e-09	3.4721e-05	5.9489e-05
13	1.7884e-09	2.2597e-05	4.2289e-05

Анализът показва най-добра ефективност за FFNN модел с 6 HN изчислителни единици за прогнозиране на „общото телетрафикно време за чакане в опашката и обработка на заявки“, показан на фиг. 5.б). Спрямо синтезираната структура са отчетени минимални показания - средноквадратична грешка 1.5496⁻⁹, средна абсолютна грешка 2.4740⁻⁵ и средно квадратично отклонение 3.9365⁻⁵.



б)

Фиг. 5. Селектирани FFNNs при вариационен анализ на SRT с а) Logsig и б) Tansig изходни функции

Изходните количествени еквиваленти потвърждават по-добрата ICT параметризация при тангенс-сигмоидална в сравнение с логаритмична-сигмоидална активация, както за единия, така и за другия трафичен индекс на производителност за обезпечаване на QoS.

4. ЗАКЛЮЧЕНИЕ

Потвърдена е високата степен на адекватност по отношение на RBNNs. Установена е неподходяща приложимост на logsig активация в изходните слоеве на FFNNs при прогнозиране за индекс ST. Сравнително по-добра адекватност е наблюдавана при комплексен индекс SRT“. Констатирана е възходяща ефективност при верификация на изходен активационен тип tansig спрямо приетите тестови индекси на производителност ST и SRT при FFNNs.

Предвижда се разширяване на обхвата на изследванията с включване на Generalized Regression Neural Networks и Cascade-Forward Neural Networks.

Благодарности: Изследванията в публикацията са реализирани и финансирани по Договор № 2406E/ 2024г. „Мониторинг на мрежовия трафик и достъп на информация чрез биометрична диагностика с изкуствен интелект“.

ЛИТЕРАТУРА

- [1] Waller J. Performance benchmarking of application monitoring frameworks. Kiel: Kiel Computer Science Series, 2014.
- [2] Dutta V. Performance analysis on throughput in 4G network in digital environment with SISO technique. International Journal of Information Technology and Computer Science 2013;2023(07):71-79.
- [3] Ferreira G., Ravazzi C., Dabbene F., Calafiore G., Fiore M. Forecasting network traffic: A survey and tutorial with open-source comparative evaluation. International Journal IEEE Access 2023;2023(1):1-28.
- [4] Lohrasbinasab I., Shahraki A., Taherkordi A., Jurcut A. From statistical to machine learning-based network traffic prediction. International Journal Transactions on Emerging Telecommunications Technologies 2021;33(4):1-29.
- [5] Zhan S., Yu L., Wang Z., Du Y., Yu Y., Cao Q., Dang S., Khan Z. Cell traffic prediction based on convolutional neural network for software-defined ultra-dense visible light communication networks. International Journal of Security and Communication Networks 2021;2021(1):1-10.
- [6] Awaforiaju T., Lasisi H., Olawuyi A., Olatunde O. Artificial neural networks of key performance indicators for mobile telecommunications. Journal of Science and Technologies 2023;15(2):43-53.
- [7] Dodan, M., Vien, Q. and Nguyen, T. Internet traffic prediction using recurrent neural networks. International Journal Endorsed Transactions on Industrial Networks and Intelligent Systems 2022;9(4):1-14.
- [8] Do Q., Doan T., Nguyen T., Duong N., Linh V. Prediction of data traffic in telecom networks based on deep neural networks. Journal of Computer Science 2020;16(9):1268-1277.
- [9] Borisov V., Borisova S., Lupinovich S., Vihor V., Torubara A. Neural networks in statistical analysis and monitoring system telecommunication network. International Journal of Advanced Trends in Computer Science and Engineering 2020;9(4):5447-5450.