

SYNTHESIS OF PREDICTIVE MODELS FOR NETWORK TRAFFIC WITH FFNNs AND TRAINING ALGORITHMS SELECTION

Teodora Valentinova Zhorova

Technical University of Gabrovo

Department of Communications Equipment and Technologies

Gabrovo, Bulgaria

teddy.tedun@gmail.com

Abstract

The paper synthesizes an approach for selecting algorithms for simulation modeling and deriving predictive models regarding performance indices of telecommunications units and systems. The object of research is a system with a queuing organization of serving incoming user requests, modeled with the application of a set of optimization algorithms. Training of three-layer artificial neural networks of Feed-Forward Neural Networks (FFNN) is involved in the variation prediction of target indices, respectively System Throughput and System Response Time. A comparative analysis between Levenberg-Marquardt, Scaled Conjugate Gradient and Bayesian Regularization training algorithms was conducted. The assessment of the quality of neural predictive models is based on accepted criteria, respectively Mean-Squared Error, Correlation coefficient, Residuals, etc.

Keywords: Optimization algorithms; System throughput; System response time; Predictive models; Neural networks.

ВЪВЕДЕНИЕ

Имитационното моделиране е един от съвременните способности, заложи в основите на „Теорията на телетрафика“, даващ възможност на потребителите за предварително планиране на различни системи без или с наличие на опашков звена за обработка на постъпващия трафик. Указаният метод на телетрафично проектиране в съчетание с методи за прогнозиране и оптимизация позволяват да се осъществи подходящо разпределяне на натоварването между обслужващите звена, управление на производителността и бързодействието за конкретна ИКТ инфраструктура на ниво симулационно изследване. От етап на предварително проучване и планиране, процесите могат да прераснат в реално изграждане на преносна среда и въвеждането на ИКТ ресурси съобразно конкретен сценарий, системен капацитет, заявени и прогнозируеми брой потребители, изи-

сквана производителност при управление на трафичните потоци и т.н. В качеството на научен апарат за прогнозен анализ с разнообразие от приложни направления за различни цели успешно се използват изкуствените невронни мрежи. Едно от тези направления разглежда „мрежовия трафик“ – TCP / UDP / IP и т.н., като основен обект на изследване, където основно приложение намират Recurrent Neural Networks (RNN), Long Short-Term Memory (LSTM) Neural Networks, Convolutional Neural Networks (CNN), Multilayer Perceptron (MLP) и т.н. [1-8].

В доклада е синтезиран подход моделиране, оптимизиране и прогнозен анализ на параметри на трафика на мрежови инфраструктури на основата на набор от алгоритми и изкуствени невронни мрежи с пряко разпространение на сигналите и обратно разпространение на грешката.

МОДЕЛИРАНЕ НА ТЕЛЕТРАФИЧНА ИНФРАСТРУКТУРА С ОПАШКА С УСТАНОВЯВАНЕ НА ОПТИМАЛНИ ИНДЕКСИ НА ПРОИЗВОДИТЕЛНОСТ

Извършено е имитационно моделиране на телетрафична система с опашкова организация на обслужването на потребителски заявки чрез графичен инструмент JMVA. По отношение на системата е заложен сценарий за администриране на трафични потоци от пакетни данни за циклично изпълнение в две фази на първична и вторична обработка. Процесът на компютърно моделиране преминава през следната последователност:

- ✓ назначаване на системен клас за целевата ИКТ инфраструктура;
- ✓ създаване на структурните възли при дефиниране на зависимост или независимост от натоварването (количеството постъпващи пакетни данни);
- ✓ задаване на времената на обслужване и процентното вероятностно разпределение на постъпванията на заявки за всеки конкретен обслужващ възел;
- ✓ избор и верификация на референтна сървърна станция при симулация на модела;
- ✓ симулиране на структурата с опашка при комплексно изследване и анализ на моделиращи алгоритми с изискване за оптималност на подбрани индекси на производителност:

При изследванията бяха селектирани като най-подходящи алгоритми:


- ✓ “MVA” (Mean-Value Analysis);
- ✓ “MoM” (Method of Moments);
- ✓ “AQL” (Aggregate Queue Length),

намиращи близки до търсеното условие за оптималност по отношение на индекси:


- “System Throughput” при търсена желана най-висока степен;
- “System Response Time”, удовлетворяващ най-ниско ниво,

Относно оценка на тяхното поведение спрямо специфициран базов индикатор “Service demand” за пакетната обслужвана информация (фиг. 1).

Приетите изисквания за оптималност на посочените трафични индекси бяха постигнати при приложение на Method of Moments, определящо най-висока пригодност и отпадането на останалите два подхода. Определянето на най-адекватен алгоритъм за моделиране на системата с опашка позволява преминаване към извеждане и изследване на модели за прогнозиране на вариациите на посочените специфични индекси на основата на концепцията „Изкуствен интелект“.



а)



б)

Фиг. 1. Индекси на производителност при имитационно моделиране с MVA, MoM и AQL алгоритми – а) „System Throughput“ и б) „System Response Time“

ОБУЧЕНИЕ И ОЦЕНКА НА FEED-FORWARD NEURAL NETWORKS ЗА ПРОГНОЗИРАНЕ АНАЛИЗ НА ЦЕЛЕВИ ТРАФИЧНИ ИНДЕКСИ НА ПРОИЗВОДИТЕЛНОСТ

Във връзка с обучение на невронни архитектури за прогнозен анализ на индекси на производителност на указаната моделирана ИКТ структура с опашкова организация бяха избрани трислойни FFNNs. По отношение на невронните мрежи са приложени идентични типове на невронна активация, съответно „тангес-сигмоидална“ и „линейна“ за скритите и изходни слоеве. Въведени са следните входни и изходни параметри в процесите на синтез на прогнозни модели:

- Входни променливи – 1) System demand, и 2) Стойностите на телеграфичния показател System demand, повдигнати на втора степен;
- Изходни параметри, съответно System Throughput и System Response Time.

Същинските процедури по изследване и подбор на FFNNs за прогнозен анализ се основават на анализ на приложимостта на следните обучаващи алгоритми:

- ✓ Levenberg-Marquardt LM;
- ✓ Bayesian Regularization (BR);
- ✓ Scaled Conjugate Gradient (SCG),

при приет базисен критерий Mean-Squared Error (MSE) в MATLAB софтуер. Съвкупните резултати от анализ на качеството на невронни модели с изменение на скритите неврони от 3 до 13 за целите на прогнозния анализ са поместени в таблица 1 и таблица 2.


Таблица 1. Резултати при изследване на невронни мрежи за прогнозиране на индекс System Throughput

Ск. нев.	LM алгоритъм	BG алгоритъм	SCG алгоритъм
	MSE при тестване	MSE при тестване	MSE при тестване
3	1.14099e-9	1.57589e-10	7.01570e-5
4	3.17825e-10	1.19221e-10	7.82394e-5
5	2.09195e-9	1.20101e-10	6.55992e-5
6	2.09897e-6	1.25709e-10	7.80464e-5
7	8.42537e-9	1.53955e-10	8.78858e-4
8	5.79434e-7	9.02992e-11	9.09759e-4
9	2.02598e-4	1.41492e-10	4.08480e-4
10	2.67695e-7	7.79211e-11	2.43299e-3
11	1.00936e-6	1.21158e-10	1.52216e-3
12	1.89889e-4	1.19690e-10	1.70738e-4
13	3.52341e-6	1.64856e-10	3.54521e-5


Относно първият заложен трафичен индекс бяха регистрирани максимални показания на грешката, респективно $MSE = 2.02598e-4$, $MSE = 1.64856e-10$ и $MSE = 2.43299e-3$ последователно при LM, BR и SCG обучение за структури с 9, 13 и 10 междинни изчислителни единици. Удовлетворяващите минимални MSEs са получени при FFNN структури със зададени 4 ($MSE = 3.17825e-10$), 10 ($MSE = 7.79211e-11$), и 13 ($MSE = 3.54521e-5$), скрити неврона, представени на фиг. 2. Според обобщените резултати избраният невронен модел с BR алгоритъм се оценява с най-висока степен на адекватност за прогнозиране на вариациите на индекс System Throughput. Сравнявайки приложените обучаващи алгоритми беше установено, че Scaled Conjugate Gradient подход се характеризира с най-ниска ефективност спрямо конкретния анализиран параметър на трафика.

Таблица 2. Резултати при невронни мрежи за прогнозиране на индекс System Response Time


Ск. нев.	LM алгоритъм	BG алгоритъм	SCG алгоритъм
	MSE при тестване	MSE при тестване	MSE при тестване
3	5.00144e-9	1.44758e-9	7.20825e-9
4	6.88759e-10	1.06745e-9	4.29007e-7
5	5.46010e-8	2.18784e-9	3.83399e-7
6	2.51603e-10	5.80534e-9	2.16496e-7
7	5.91742e-9	2.67628e-9	9.91093e-8
8	5.50524e-9	6.38057e-10	2.55897e-7
9	5.41969e-11	1.65099e-9	3.60012e-8
10	7.73573e-9	1.15110e-9	2.06796e-7
11	1.20022e-9	4.25863e-10	1.38354e-7
12	5.58102e-10	6.71894e-10	1.37807e-7
13	1.36464e-11	1.61493e-9	6.66151e-8



a)




б)




в)


Фиг. 2. Селектирани прогнозни FFNNs за индекс на производителност System Throughput при а) LM, б) BR и в) SCG



а)



б)




в)


Фиг. 3. Селектирани прогнозни FFNNs за индекс на производителност System Response Time при а) LM, б) BR и в) SCG

Спрямо синтеза на прогнозни модели при вторият заложен телетрафичен показател, обхващащ „Времената на престой в опашката и обработка на постъпилите заявки (system Response Time)“, относително беше наблюдавана известна тенденция на по-малка ефективност при SCG в сравнение с останалите използвани алгоритми. Но съблюдавайки изходните сте-


пени на критерия за качество MSE, тук се отличава изразено предимство на SCG спрямо подбора на невронни модели при “Системната пропускателна способност”. Най-големите грешки $MSE = 5.46010e-8$, $MSE = 5.80534e-9$ и $MSE = 4.29007e-7$ бяха констатирани при FFNNs със съдържание на 5, 6 и 4 скрити неврона, респективно при LM, BR и SCG алгоритми. Постигачи изискването за минимизация на грешката са невронни архитектури при наличие на 13 за LM, 11 при BR и 3 структурни междинни неврона относно SCG обучение – $MSE = 1.36464e-11$, $MSE = 4.25863e-10$ и $MSE = 7.20825e-9$, показани на фиг. 3. Съпоставяйки избраните крайни FFNN модели за прогнозиране на System Response Time се откроява предимството на Levenberg-Marquardt алгоритъм на обучение пред Bayesian Regularization и Scaled Conjugate Gradient.



а)

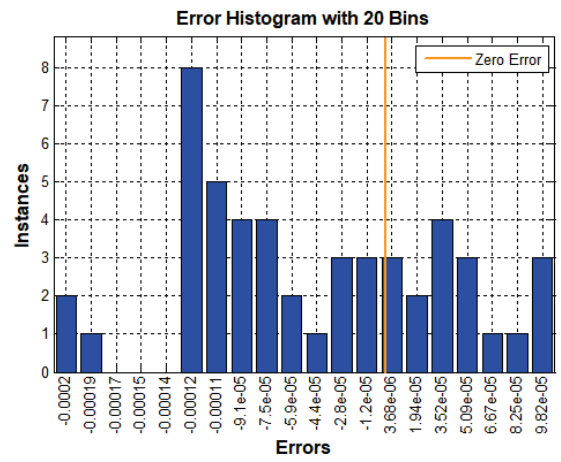


б)




в)

Фиг. 4. Хистограми на грешките за избраните FFNNs за индекс на производителност System Throughput при а) LM, б) BR и в) SCG




б)

Фиг. 5. Хистограми на грешките за избраните FFNNs за индекс на производителност System Response Time при а) LM, б) BR и в) SCG



а)



б)

В следващ етап от изследванията бяха анализирани параметричните остатъци или разликите между заложените при обучение теоретични нива на System Throughput и System Response Time и техните прогнозни прагове, получени с приложение на синтезираните FFNNs. Хистограмите на грешките, дадени на фиг. 4 и фиг. 5, са построени при приети 20 числови интервали, индивидуално определени в хода на експеримента за всеки конкретен изследван трафичен индекс на производителност.

Целта е да бъде илюстрирано разпределението на остатъците, асоциирани към съответни интервали, спрямо „нулевата грешка“. По отношение на индекс на производителност System Throughput най-голям дял от остатъците попадат към интервали „-2.7e-06“ при LM; „-7.5e-06“, „1.43e-06“, „6.8e-06“ и „1.57e-05“ за приложен BR и регистрираната най-висока степен „0.00209“ относно SCG алгоритъм.

В отчетена непосредствена близост в обхвата на интервал до „нулевата грешка“, съответно „-6.8e-08“, са асоциирани най-голям брой остатъци за Levenberg-Marquardt при индекс System Response Time. Най-голямо количество параметрични остатъци за случаите на BR и SCG обучаващи алгоритми бяха намаре-

ни за числовите зони „2.1e-05“ и „-0.00012“.

ЗАКЛЮЧЕНИЕ

Приложеният невронен апарат показва много добри индикации предвид постигнатите минимални нива на MSE при оценка на качествата на прогнозните FFNNs. Обхватът на аналитичния инструмент може да се разшири чрез включване на процедури с Класически регресионен анализ, Cascade-Forward невронни мрежи, Регресионни дървета на решения, Обобщени регресионни невронни мрежи и др. Създадените невронни модели следва да бъдат внедрени в приложения при планиране и мониторинг на трафика в ИКТ инфраструктури с бизнес и индустриална насоченост.

REFERENCE

- [1] Ardakanin O., Keshav S., Rosenberg C. On the use of teletraffic theory in power distribution systems. In: Proceedings of the of the third international conference on future energy systems: Where energy, computing and communication meet, vol. XXI, 2012, pp. 211-226.
- [2] Akimaru H., Kawashima K. Teletraffic: Theory and application. Springer, 2012, 1(1):1-221.
- [3] Rao G., Rao Ch., Prasad K. Teletraffic and blocking probability estimation of OFDMA system. Procedia Computer Science 2016, 85(1): 696-704.
- [4] Miraz M., Ganie M., Molvi S., Ali M. Simulation and analysis of quality of service (QoS) parameters of voice over IP (VoIP) traffic through heterogeneous networks. International Journal of Advanced Computer Science and Applications 2017, 8(7):242-248.
- [5] Ferreira G., Ravazzi C., Dabbene F., Calafiore G., Fiore M. Forecasting network traffic: A survey and tutorial with open-source comparative evaluation. IEEE Access 2023, 99(1):1-28.
- [6] Joshi M., Hadi T. A review of network traffic analysis and prediction techniques. Computer Science 2015, 1(1):1-77.
- [7] Abbasi M., Shahraki A., Taherkordi A. Deep learning for network traffic monitoring and analysis: A survey. Computer Communications 2021, 170(2021):19-41.
- [7] Shihao W., Qinzheng Z., Han Y., Yong Q. A network traffic prediction method based on LSTM. ZTE Communications 2019, 17(2):19-25.