

**ПРОГНОЗИРАНЕ НА КОМУНИКАЦИОННО ТРАФИЧНО
НАТОВАРВАНЕ ПОСРЕДСТВОМ ИЗКУСТВЕНИ НЕВРОННИ МРЕЖИ**

Ивелина Балабанова Станимир Садинов Дионисия Даскалаки Георги Георгиев
Технически университет – Габрово, Катедра „Комуникационна техника и технологии“
ivstoeva@abv.bg, murry@tugab.bg, dionisia_d@abv.bg, givanow@abv.bg

**PREDICTION OF COMMUNICATION TRAFFIC LOAD
BY ARTIFICIAL NEURAL NETWORKS**

Ivelina Balabanova Stanimir Sadinov Dionisia Daskalaki Georgi Georgiev
Technical University of Gabrovo, Department of Communications Equipment and Technologies
ivstoeva@abv.bg, murry@tugab.bg, dionisia_d@abv.bg, givanow@abv.bg

Abstract

This paper presents an approach for prediction variance of the average served traffic on the basis of artificial intelligence. The objective of quantitative analysis is the traffic flow of users' requests through the server stations of the telecommunication system M/M/c/k. Regression modeling procedures were performed by Generalized Regression Neural Networks (GRNNs), Feed-Forward Neural Networks (FFNNs) and Cascaded-Forward Neural Networks (CFNNs). Neural architectures with different numbers and combinations of predictors have been tested. FFNNs on the basis of Levenberg-Marquardt (LM), Bayesian Regularization (BR) and Scaled Conjugate Gradient (SCG) learning algorithms were examined. The factors influence on the target forecast parameter has been analyzed. In the course of the research, satisfactory levels of different criteria – Mean Squared Error (MSE), Mean Absolute Error (MAE) and Correlation Coefficient R, have been obtained. Advantages of FFNN and CFNN models over GRNNs were established.

Keywords: teletraffic system; traffic load; factor combinations; regression modeling; neural networks.

ВЪВЕДЕНИЕ

Според научните изследвания прогнозният анализ в сферата на комуникациите засяга две основни направления:

- намаляващия приток от потребители на услуги в мобилната телекомуникационна индустрия поради възникнали прекъсвания или непредвидени събития;
- цялостния трафик от постъпили потребителски заявки в обслужвани в телекомуникационни, LTE мрежи.

Основните инструменти, използвани за количествено прогнозиране по отношение на тях, са машинното обучение, приложната статистика и изкуствените невронни мрежи. Тук могат да бъдат споменати, както следва:

- метод на опорните вектори (SVM);
- метод дърво на решенията;
- Бейсови мрежи;
- логистична регресия;
- многослойни перцептрони;
- рекурентни невронни мрежи;
- регресионни модели на основата на SVM или SVR модели;
- конволюционни невронни мрежи;
- адаптивни невронно-размити интерфейсни системи [1-6].

Обект на изследване в настоящия доклад са имитационно моделирани телекомуникационни системи с опашкова организация от вида „Марковски вериги“ M/M/c/k. Разглежда се задачата за синтез на модели за прогнозен анализ на потенциалния среден сумарен трафик заявки в опашката и обслужени заявки, които могат да бъдат обрабо-

тени от системните структурни станции „у“. Входни параметри за моделите са:

- средната скорост на постъпване на повиквания „ x_1 “;
- средното обслужващо време „ x_2 “;
- максималният капацитет на заявките - опашката „ x_3 “.

За целта е предложен подход на основата на изкуствени невронни мрежи с радиално-базисни функции, право разпространение на сигналите и обратно разпространение на грешката – GRNNs, FFNNs и CFNNs.

ИЗЛОЖЕНИЕ

Предварителни изследвания, базирани на регресионен анализ при обектна телетрафична система М/М/1

В начална фаза от изследванията беше направена оценка на приложимостта на апарата на класическия регресионен анализ спрямо първите два дефинирани управляеми фактора верига на Марков М/М/1. Беше анализирана адекватността на модели от нулева, първа и втора степен като резултатите са показани на фиг. 1.

Regression Summary for Dependent Variable: y1 (m-m-1)						
R= .75137946 R ² = .56457109 Adjusted R ² = .53818146						
F(2,32)=21.394 p<.00000 Std.Error of estimate: 1.0366						
N=36	b*	Std. Err. of b*	b	Std. Err. of b	t(33)	p-value
Intercept			-2.42048	0.550424	-4.39749	0.000108
x1	0.504320	0.114869	4.44143	1.011622	4.39040	0.000110
x2	0.556985	0.114869	1.88663	0.389085	4.84889	0.000029

а)

Regression Summary for Dependent Variable: y1 (m-m-1)						
R= .90029822 R ² = .81053688 Adjusted R ² = .79277471						
F(3,32)=45.633 p<.00000 Std.Error of estimate: .69438						
N=36	b*	Std. Err. of b*	b	Std. Err. of b	t(32)	p-value
Intercept			0.92390	0.636538	1.45144	0.156391
x1	-0.445059	0.166183	-3.91953	1.463532	-2.67813	0.011587
x2	-0.604608	0.195959	-2.04794	0.663757	-3.08537	0.004172
x12	1.580058	0.245145	9.83642	1.526114	6.44540	0.000000

б)

Regression Summary for Dependent Variable: y1 (m-m-1)						
R= .94190570 R ² = .88718634 Adjusted R ² = .86838407						
F(5,30)=47.185 p<.00000 Std.Error of estimate: .55339						
N=36	b*	Std. Err. of b*	b	Std. Err. of b	t(30)	p-value
Intercept			3.3100	0.757580	4.36915	0.000137
x1	-1.40401	0.361046	-12.3648	3.179645	-3.88873	0.000518
x2	-1.56469	0.315829	-5.3000	1.069781	-4.95424	0.000027
x12	1.58006	0.195369	9.8364	1.216242	8.08755	0.000000
x11	0.97480	0.341430	10.5565	3.697493	2.85506	0.007734
x22	0.98375	0.281281	1.9130	0.546966	3.49738	0.001487

в)

Фиг. 1. Резултати при проверка на адекватността на модели от а) нулева, б) първа и в) втора степен относно у при М/М/1

Установени са следните коефициенти на определеност $R^2 = 0.56457109$, $R^2 = 0.81053688$ и $R^2 = 0.88718634$ за отклика на обекта у, определящи линейния модел като неадекватен. Поради регистрираното по-занижено сходство между теоретичните и прогнозни-

те резултати, на базата на стойности на R^2 близки, но под прага от „0.9“, възникна необходимостта от търсене на по-ефективни инструменти за прогнозен анализ спрямо разглежданата и основната телетрафична система М/М/с/к.

Синтез на GRNN модели за прогнозен анализ на натоварването при Марковска верига М/М/с/к

Създадени са GRNNs при фиксирани 45 структурни изчислителни единици в радиално-базисните слоеве. Същинските процеси на изследване бяха разделени в три фази, състоящи се в подбор на архитектури на базата на различно количество от обучаващи променливи, съответно:

- единични входни въздействия;
- комбинации от два управляеми фактора;
- набор от три независими информативни признака.

Бяха оценени два базисни показателя, респективно “Mean Squared Error” and “Mean Absolute Error”, при стъпково нарастване на „spread“ indicator при идентични нива от „0.15“ до „0.95“ относно структурните неврони с радиално-базисните слоеве.

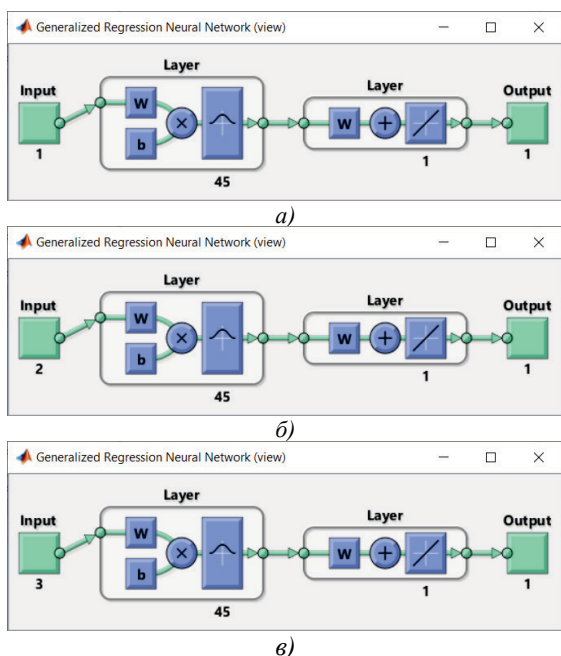
Прилагането на индивидуални входни променливи x_1 и x_2 се свързва с наблюдавани значителни степени на нарастване на показателите за качество при увеличаване на стойността на spread индикатора. Значително подобряване на показателите беше установено при модели с подаване на управляем фактор x_3 . При използване на комбинации от две входни променливи са констатирани най-ниски индикации за качество при двойка “ x_1 и x_2 ”. Откроява се значително по-добрата ефективност при архитектури с приложени комбинации от променливи “ x_1 и x_3 ” и “ x_2 и x_3 ”. Също така се забелязват леки преимущества при невронните мрежи, обучени “ x_1 и x_3 ”, пред останалите приложени двойки от управляеми фактори.

Последната фаза от синтез на GRNN модели за прогнозен анализ се състои в оценка на MSE and MAE индикатори спрямо плавно увеличаване of the spread parameter за случая на използване на три входни променливи. При подаване на входна комбинация “ x_1 , x_2 and x_3 ” бяха получе-

ни най-добри количествени индикатори в хода на направените изследвания, спрямо които указаната GRNN архитектура се оценява с най-висока степен на адекватност. Установени са числови диапазони от $4.8341e-04$ до $6.3031e-04$ относно MSE и от 0.0196 до 0.0211 за MAE критерии, както може да бъде видяно от таблица 1.

Таблица 1. MSE и MAE показатели при синтез на обобщени регресионни невронни мрежи за прогнозиране на обслужваните заявки при верига на Марков M/M/c/k при прилагане на три входни променливи

Spread индикатор	MSE	MAE	
		X1, X2 И X3	
0.15	4.8341e-04		0.0196
0.20	4.9686e-04		0.0199
0.25	5.0315e-04		0.0200
0.30	5.0649e-04		0.0201
0.35	5.0809e-04		
0.40	5.0848e-04		
0.45	5.0859e-04		
0.50	5.0985e-04		
0.55	5.1345e-04		
0.60	5.1987e-04		
0.65	5.2899e-04		0.0202
0.70	5.4050e-04		
0.75	5.5414e-04		0.0205
0.80	5.6983e-04		
0.85	5.8766e-04		
0.90	6.0776e-04		0.0209
0.95	6.3031e-04		0.0211



Фиг. 2. Изследвани архитектури на обобщени регресионни невронни мрежи за прогнозиране на обслужваните заявки при верига на Марков M/M/c/k при а) една, б) две и в) три входни променливи

На фиг. 2 е онагледен видът на анализираниите архитектури на обобщени регресионни невронни мрежи при една, две и три входни променливи. По отношение на целите на прогнозния анализ на потенциалното средно трафично натоварване на сървърни станции при верига M/M/c/k са избрани модели при комбинации “ x_1 и x_2 ”, “ x_1 и x_3 ”, “ x_2 и x_3 ” и намерената с най-добри показатели GRNN при “ x_1 , x_2 и x_3 ” при най-малка широчина на радиално-базисните функции на ниво „0.15“.

Селекция на FNNN архитектури за прогнозен анализ на натоварването при теле-трафична система M/M/c/k

Базирайки се на установените предимства при получаване на прогнозни модели чрез изкуствен интелект се формира основа на разширяване на изследванията в това направление. В тази посока беше заложена задачата за синтез на FFNN модели при тангенс-сигмоидална и линейна активации за прогнозен анализ на параметъра средното трафично натоварване при различни двойки променливи и три управляеми фактора на обекта в хода на следните обучаващи градиентни подходи:

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

Въведени базисни критерии във връзка с оценка на ефективността са „средноквадратичната грешка“ и „корелационният коефициент“ като първият е приет с по-висока значимост. Показателите са отчетени съгласно тестовите процеси на целевите невронни архитектури при зададено количествено изменение на скритите неврони от 5 до 15. Предвид регистрираните порядъци „ $e-2$ “ и „ $e-3$ “ на преобладаваща част от средноквадратичните грешки – таблица 2 до таблица 4 при комбинация “ x_1 , x_2 и x_3 ”, използваният SCG се определя като най-малко ефективен. Най-висока степен на адекватност спрямо задачата за прогнозен анализ беше установена при BR обучение за разглежданите случаи от входни въздействия.

Таблица 2. Резултати при FFNN модели за прогнозен анализ при входни променливи x_1, x_2 и x_3 за LM обучение

Скрити неврони	Levenberg-Marquardt	
	MSE при тестване	R при тестване
5	4.45379e-5	0.999953
6	1.92693e-5	0.999974
7	2.03792e-4	0.999765
8	5.36125e-5	0.999932
9	2.52754e-5	0.999972
10	2.96257e-5	0.999971
11	2.17546e-5	0.999946
12	5.18882e-5	0.999932
13	3.82764e-5	0.999971
14	9.36914e-5	0.999794
15	4.31546e-5	0.999974

Таблица 3. Резултати при FFNN модели за прогнозен анализ при входни променливи x_1, x_2 и x_3 за LM обучение

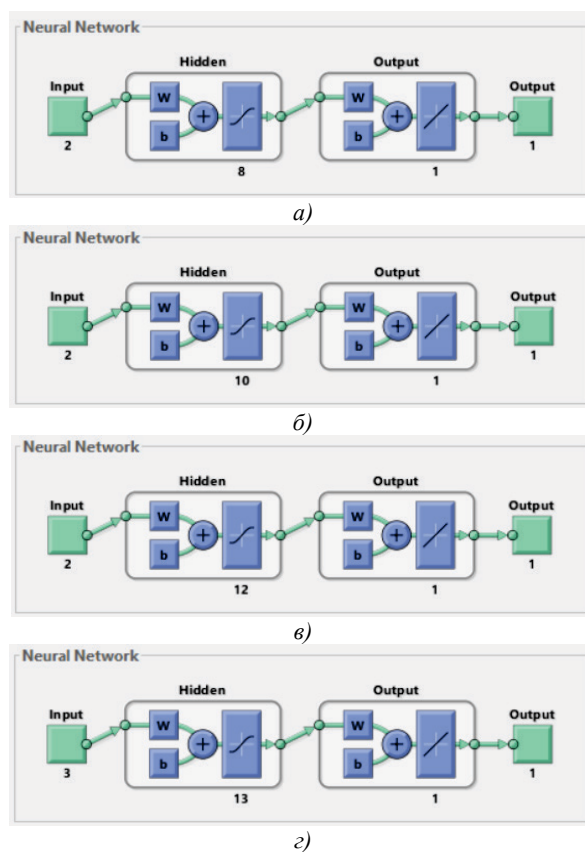
Скрити неврони	Bayesian Regularization	
	MSE при тестване	R при обучение
5	1.84230e-5	0.999949
6	3.52834e-5	0.999977
7	2.75634e-5	0.999975
8	1.19765e-5	0.999982
9	2.78891e-5	0.999986
10	2.05384e-5	0.999990
11	2.27914e-5	0.999955
12	1.43303e-5	0.999972
13	8.88908e-6	0.999975
14	3.22447e-5	0.999974
15	2.24857e-5	0.999975

Таблица 4. Резултати при FFNN модели за прогнозен анализ при входни променливи x_1, x_2 и x_3 за LM обучение

Скрити неврони	Scaled Conjugate Gradient	
	R при валидиране	R при тестване
5	4.25524e-4	0.999586
6	2.09231e-3	0.998037
7	1.79957e-3	0.997545
8	4.03832e-3	0.999654
9	1.67612e-4	0.999211
10	1.19369e-3	0.998780
11	3.40757e-3	0.991529
12	1.46945e-2	0.990674
13	7.13208e-3	0.990926
14	1.94604e-2	0.976522
15	5.76271e-3	0.975872

Във връзка с прилагането на комбинации от две входни променливи са отчетени положителни индикации на подобряване на нивата на MSE в сравнение с GRNNs. В етапа на изследванията при “ x_1, x_2 и x_3 ” въздействия бяха установени минимални показатели MSE = 1.92693e-5, MSE = 8.88908e-6 and MSE = 1.67612e-4, респективно при 6, 13 и 9 структурни скрити неврона при по-

следователно прилагане на LM, BR and SCG алгоритми. Регистрираните MSE в минимални граници от порядък „...e-6“ дават основание FFNNs да бъдат определени като инструмент за регресионно моделиране с потвърдена по-добра ефективност спрямо апарата на GRNNs. Фигура 3 представя крайните селектирани FFNN модели при 8, 10, 12 и 13 неврони в междинните слоеве за указания алгоритъм, респективно при подаване на “ x_1 и x_2 ”, “ x_1 и x_3 ”, “ x_2 и x_3 ” и “ x_1, x_2 и x_3 ”.



Фиг. 3. Синтезирани feed-forward невронни модели за прогнозен анализ на трафикното натоварване на базата на BR обучение при а) x_1 и x_2 , б) x_1 и x_3 , в) x_2 и x_3 и г) x_1, x_2 и x_3

Изследване на CFNNs за прогнозен анализ на трафикното натоварване при Марковска верига M/M/c/k

Последният етап от изследванията се отнася до прилагане на разновидност на FFNN архитектурите, при която е налице структурна връзка между входния и изходния слой или така наречените Cascade-forward Neural Networks за апроксимация относно отклик на обекта у. По отношение на изходния линеен слой добавянето на функционална връзка се отразява във

включване на втора тегловна матрица. Във връзка с обучението на CFNN отново е използван алгоритъмът на Levenberg-Marquardt при тестови модели със съдържание от 5 до 15 скрити неврони с тангенс-сигмоидална активация.

В таблица 4 и таблица 5 са обобщени данни за средноквадратичната грешка във връзка с CFNNs при двойки и набор от три управляеми фактора. Обща характеристика на тестовите модели са регистрираните изменения на MSE от порядъка „ $e-05$ “.

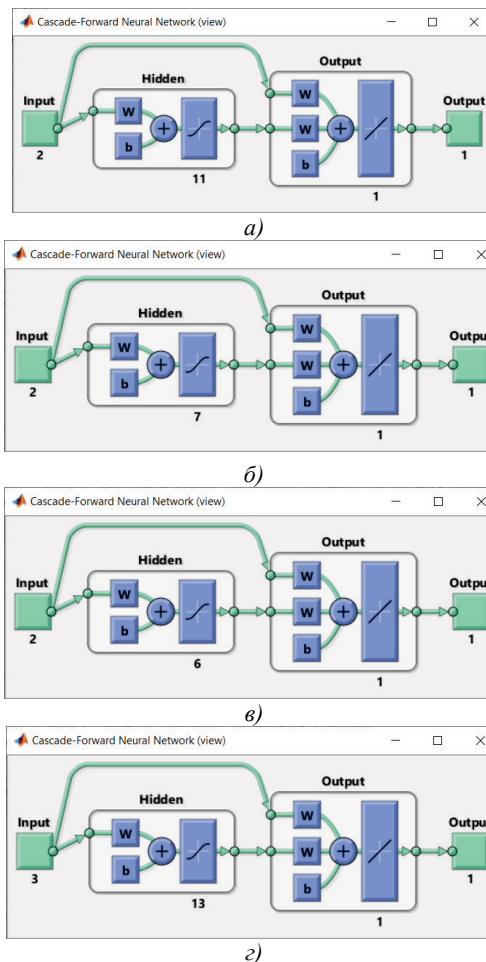
За всяка анализирана комбинация от входни променливи - “ x_1 и x_2 ”, “ x_1 и x_3 ”, “ x_2 и x_3 ” и “ x_1, x_2 и x_3 ”, е избрана CFNN архитектура с най-приемливи нива съобразно изискванията за минимизация на критерия MSE, съответно $MSE = 8.1190e-06$, $MSE = 9.4212e-06$, $MSE = 7.6726e-06$ и $MSE = 9.2107e-06$. Указните стойности на грешката са отчетени при модели с 11, 7, 6 и 13 междинни неврона, показани на фиг. 4.

Таблица 4. Резултати при изследване на CFNNs за прогнозен анализ при “ x_1 и x_2 ”, “ x_1 и x_3 ” при LM обучение

Скрити неврони	MSE при x_1 и x_2	MSE при x_1 и x_3
5	2.8061e-05	1.3164e-05
6	1.1751e-05	1.1977e-05
7	2.0405e-05	9.4212e-06
8	9.8043e-06	1.3144e-05
9	1.8516e-05	1.4764e-05
10	1.7005e-05	2.9226e-05
11	8.1190e-06	1.2741e-05
12	8.3677e-06	1.4098e-05
13	2.6177e-05	2.9015e-05
14	1.0827e-05	9.8218e-06
15	1.0253e-05	1.8246e-05

Таблица 5. Резултати при изследване на CFNNs за прогнозен анализ при “ x_2 и x_3 ”, “ x_1, x_2 и x_3 ” при LM обучение

Скрити неврони	MSE при x_2 и x_3	MSE при x_1, x_2 и x_3
5	4.8955e-05	1.0164e-05
6	7.6726e-06	1.6125e-05
7	2.0250e-05	2.2224e-05
8	1.2254e-05	1.0584e-05
9	1.0857e-05	6.1230e-05
10	1.9434e-05	1.0617e-05
11	1.5408e-05	3.4340e-05
12	1.9071e-05	2.1702e-05
13	3.4903e-05	9.2107e-06
14	2.0853e-05	2.2893e-05
15	3.7645e-05	1.3529e-05



Фиг. 4. Селектирани cascade-forward невронни архитектури за прогнозен анализ на обслужваните потребители при а) x_1 и x_2 , б) x_1 и x_3 , в) x_2 и x_3 и г) x_1, x_2 и x_3

ЗАКЛЮЧЕНИЕ

По отношение на моделите за прогнозен анализ на потенциалния обслужван трафик при М/М/с/к са проведени допълнителни процедури по оценка на ефективността, изразяващи се в:

- извеждане на MSE за мрежово обучение, валидиране и тестване;
- построяване на линейни регресионни зависимости за мрежовите изходи;
- генериране на хистограми на грешките;
- верификация с информационни еталони извън използваните в хода на синтез.

REFERENCE

- [1] Sharma A., Panigrahi P. A neural network based approach for predicting customer churn in cellural network services. International Journal of Computer Applications 2021;27(11):26-31.

- [2] Brandusoiu I., Todorean G. A neural network approach for churn prediction modeling in mobile telecommunications industry. Annals of University of Craiova 2014;11(1):9-16.
- [3] Adlan O., Faris H., Jaradat K., Harfoushi O., Ghatasheh N., Abdullah K. Predicting customer churn in telecom industry using multilayer perceptron neural networks: Modeling and analysis. Life Science Journal 2014;11(3):75-81.
- [4] Mastorocostas P., Hilaris C., Varsamis D., Dova S. A recurrent neural network-based system in telecommunications call volume. International Journal of Applied Mathematics & Information Sciences 2013;7(5):1643-1650.
- [5] Gijon C., Toril M., Luna-Ramirez S., Mari-Altozano M., Ruiz-Aviles J. Long-term data traffic forecasting for network dimensioning in LTE with short time series. Electronics 2021;10(1151):1-19.
- [6] Do Q., Doan T., Nguyen Th., 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.