

NOISE CLASSIFICATION AND TRAFFIC PARAMETER PREDICTION IN ICT INFRASTRUCTURES WITH ARTIFICIAL NEURAL NETWORKS

Georgi Ivanov Georgiev

*Technical University of Gabrovo
Department of Communications Equipment and Technologies
Gabrovo, Bulgaria
givanow@abv.bg*

Abstract

The paper proposes a combined approach for monitoring the transmission media ICT-based infrastructures with the integration of Artificial Intelligence. In this study two directions have been introduced, respectively "identification of noise superimposed on transmitted signals" and "prediction of the current arrival time of service requests". With regard to the first direction, the main objects of research are Gaussian White Noise (GWN) and Periodic Random Noise (PRN). While the second involves parametric studies in the telecommunication queuing systems. The approach examines the applicability of three-layer Backpropagation neural networks at Scaled Conjugate Gradient (SCG) and Levenberg-Marquardt (LM) training algorithms on models for classification and predictive analysis. A successful confirmatory verification of the final selected neural structures was performed.

Keywords: Neural networks; Backpropagation; Noise recognition; Queuing arrival time; Predictive analysis.

ВЪВЕДЕНИЕ

Наличието на съпътстващи постоянни фонове или случайно възникнали смущения в комуникационните канали за връзка непосредствени се отразява негативно в качеството на предаваната информация. Обект на възникване от случайни процеси в различни възли в електрическата част и звената за предаване в комуникационните системи най-често срещани са Thermal Noise, White Noise, Additive Noise [1]. Негативният ефект на шумовете основно се изразява в няколко типа нелинейни изкривявания - Harmonic Distortion/Amplitude Distortion, Intermodulation Distortion, Frequency Response Distortion, Phase Distortion [2]. Тези ефекти е важно е не само да бъдат минимизирани, но и да се идентифицира техният вид. В тази връзка успешно се използват аналитичните инструменти на Machine Learning (ML). Подобни дейно-

сти са реализирани в [3], където са синтезирани Дискриминантни класификатори разпознаване на UWM и PRN към аналогови и цифрови сигнали без и с FFT обработка. Изследване в съответното направление разширява спектъра от прилагани математически апарати чрез Изкуствени невронни мрежи при Levenberg-Marquardt обучение, тангенс-сигмоидална и логаритмична-сигмоидална невронна активация [4].

Освен анализа на шумовете въздействия, съществен аспект при планиране на QoS в комуникационните системи е количественият анализ на мрежовия информационен трафик. Тук се използват способите на „дълбокото на обучение“ при Recurrent Neural Networks (RNNs), Convolutional Neural Networks (CNNs), Adaptive Neuro-Fuzzy Interface Systems (ANFIS) [5]. Подходи с включване на аналитични инструменти за статистиче-

ска диагностика и оптимизация като Hidden Markov Model (HMM), Bayesian Estimation впоследствие се използват за прогнозен анализ в съчетание с Linear Regression с Long Short-Term Memory (LSTM) - вариант на RNN, Backpropagation Neural Networks (BPNNs) [6]. В [7] LSTM и RNN се прилагат в подходи с Gated Recurrent Units (GRUs) и Online Sequential Extreme Learning Machine (OS-ELM) по отношение на тестови мрежови трафик. Някои от методите за многовариантен избор на решения – например Vector Autoregressive (VAR), Vector Moving Average (VMA), Vector Autoregressive Moving Average (VARMA), се комбинират с Neural Networks, Support Vector Machines (SVM), Fuzzy Logistic, ANFIS при процедурно прогнозиране на трафика [8]. В редица проучвания често обект на прогнозен анализ е трафичното натоварване на обслужващите звена, където се използват хибридни ML похвати - Diffusion Convolutional Recurrent Neural Network (DCRNN); Generalized Regression Neural Networks (GRNNs) и Cascade-Forward Neural Networks (CFNNs) [9, 10].

В настоящия доклад е предложен хибриден подход с интеграция на трислойни Feed-Forward Neural Networks с обучение, базирано на градиентни методи с тяхно основно предимство за редуциране на грешката на всяка обучаваща итерация, за класификация и прогнозен анализ на шумови въздействия и индекси на пакетното предаване на данни в моделирани ИКТ обслужващи системи.

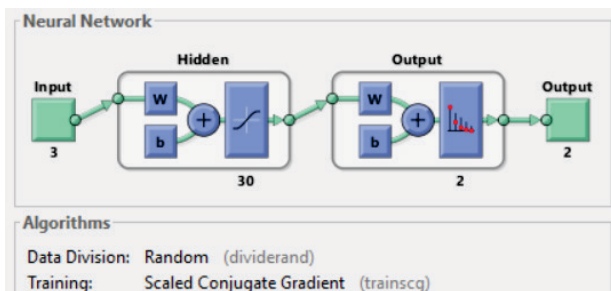
НЕВРОННИ СТРУКТУРИ ЗА ИДЕНТИФИКАЦИЯ НА ШУМОВИ ВЪЗДЕЙСТВИЯ КЪМ ЦИФРОВИ СИГНАЛИ

Поставена е задачата за обучение и подбор на трислойна FFNN архитектура при градиентно обучение чрез Scaled Conjugate Descent алгоритъм. Обект на изследване са цифрови сигнали с насложени GWN и PRN. Приет е подбор на невронни модели при оценка на кри-

териите „Точност“ и „Cross-Entropy“, анализирани при постепенно увеличаване на изчислителните единици в междинния слой на тестовите архитектури. Таблица 1 обобщава данните от процедурите по оценка на качеството на моделите за шумова идентификация. Обща тенденция се оказва високото ниво на точността над 90.00 %, което определя адекватността на приложения вид невронно обучение за съответния вид изкуствени невронни мрежи. Минимална точност 96.50 % и най-висока ентропия 5.45908e-0 са установени при структури със съдържание на 46 и 36 скрити неврона. Предвид по-високия ранг на „точността“ като индекс на производителност относно целите на задачата беше избрана архитектура с 30 междинни неврона с постигната максимална точност 99.30 %, чиято архитектура е показана на фиг. 1.

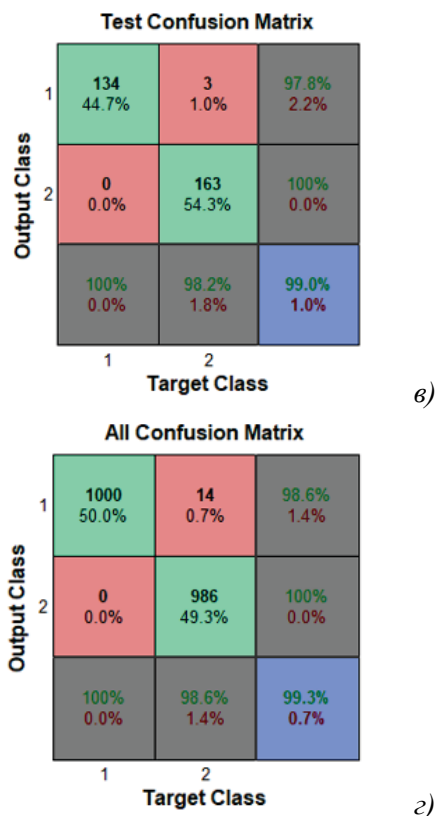
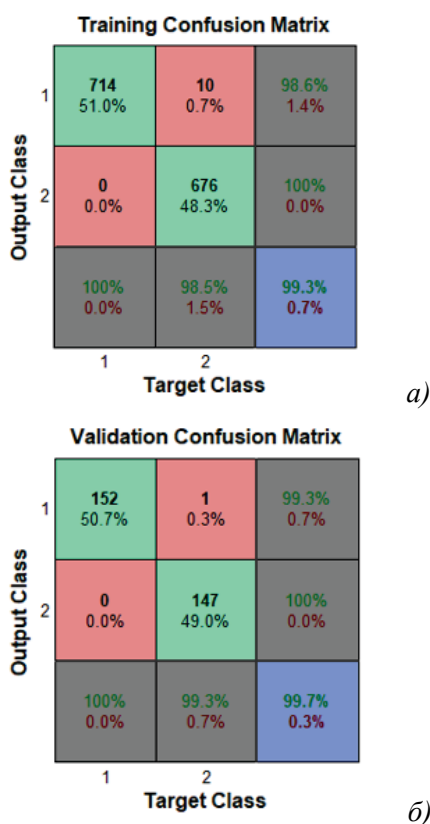
Таблица 1. Оценка на качеството на FFNN модели за идентификация на шумове при Scaled Conjugate Gradient обучение

Невронни единици в скрития слой	Точност, %	Cross-Entropy
20	99.00	3.56245e-0
22	98.90	3.59019e-0
24	96.90	2.22453e-0
26	97.70	2.63779e-0
28	97.30	2.57719e-0
30	99.30	5.08019e-0
32	96.80	1.95615e-0
34	98.00	2.68853e-0
36	99.20	5.45908e-0
38	99.20	4.71057e-0
40	97.70	2.37335e-0
42	98.20	2.98908e-0
44	98.60	3.47991e-0
46	96.50	2.16416e-0
48	98.60	3.48101e-0
50	96.90	2.17100e-0



Фиг. 1. Избран невронен модел с SCG обучаващ алгоритъм за идентификация на GWN и PRN към цифрови сигнали

По отношение на селектираната невронна архитектура са получени матрици на коректни и некоректни класификации на фиг. 2. Матриците показват постигнати точности - 99.30 % за обучение, 99.70 при валидация, 99.00 % от тестване и 99.30 % еквивалент на обща крайна точност. Допълнително може да анализирана информация, касаеща специфичните класификационни параметри „Прецизност“, „Чувствителност“ и т.н.




Фиг. 2. Класификационни матрици за невронен модел за идентификация на GWN и PRN към цифрови сигнали – а) обучение, б) валидиране, в) тестване и г) общ индекс

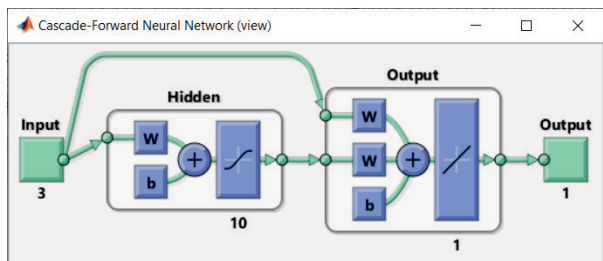
ПРОГНОЗЕН АНАЛИЗ НА ВРЕМЕТО НА ПОСТЪПВАНЕ НА ЗАЯВКИ ЗА ОБРАБОТКА В ОБСЛУЖЖВАЩИ ЗВЕНА С ИЗКУСТВЕН ИНТЕЛЕКТ

Един от основните проблеми пред съвременните ИКТ системи е момента на обработка на постъпващите заявки, определящо бързодействието и ефективността на системите. В тази връзка бяха използвани два вида трислойни изкуствени невронни мрежи с фиксиран идентичен обучаващ алгоритъм (LM), съответно:

- ❖ Network № 1: Feed-Forward Neural Networks – FFNNs;
- ❖ Network № 2: Cascade-Forward Neural Networks – CFNNs.



a)



б)

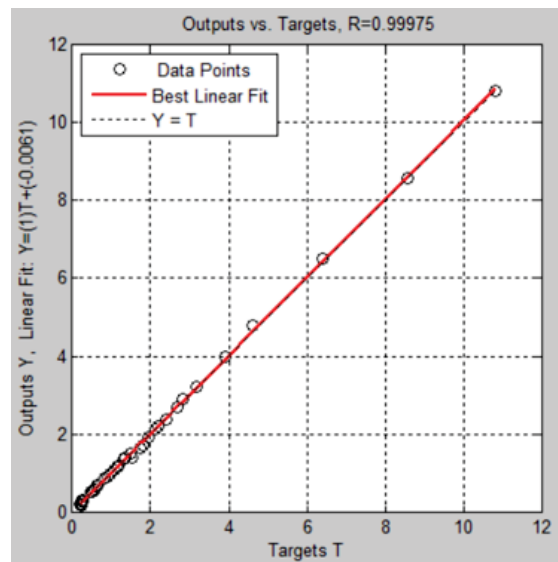
Фиг. 3. FFNN a) и CFNN б) за прогнозиране на вариациите на момента на постъпване на заявки за текуща обработка

Относно изследваните тестови невронни модели са приложени трафични входни променливи, както следва:


- ❖ Скорост на постъпване на потребителски заявки;
- ❖ Залагано време за обслужване;
- ❖ Места за чакане в опашката,

при имитирана ИКТ инфраструктура в симулационна среда. Изходният параметър, който е обект на прогнозен анализ, е „Потенциалното време на постъпване на заявки“. Процедурната оценка на невронните апарати е основана на приет еднакъв критерий „Средноквадратична грешка – Mean-Squared Error“. Невронното обучение отново е проведено в избран диапазон на плавно увеличаване на невроните в скритите структурни слоеве - 5 до 30.

На фиг. 3 са показани селектираните FFNN и CFNN архитектури за прогнозен анализ на посочения информационен параметър с регистрирани минимални грешки $MSE = 0.0030$ и $MSE = 0.0011$. Установените нива на грешката се приемат за удовлетворяващи като съществени предимства са постигнати за приложеният втори невронен вид.



a)




б)

Фиг. 4. Линии на регресия за FFNN a) и CFNN б) за прогнозиране на времето на постъпване на заявки с информация

На фиг. 4 са получени линейни регресионни зависимости за мрежовите изходи. При двете невронни архитектури е наблюдавано много близко приближение между теоретичните и опитни линии на регресия. Качествата на невронните мрежи допълнително се потвърждават от констатираните високи стойности на корелационните коефициенти, респективно за FFNN $R = 0.99975$ и $R = 0.99989$ при CRNN, където по-добрите индекси на мрежова производителност в минимална

степен отново са получени за втората използвана невронна структура.



Фиг. 5. Диаграми на грешките при CFNN за прогнозиране на времето на постъпване заявки към обслужващите звена

Предимствата на втората архитектура са по-видимо изразени при диаграмата на мрежовите грешки на фиг. 5. Техните вариации са лимитирани в интервала „-0.1710 до 0.1172“ при FFNN и „-0.0131 до 0.0099“. Всичко това определя CFNN като невронен апарат с по-подходяща приложимост за конкретният случай на прогнозна задача.

ЗАКЛЮЧЕНИЕ

Получените крайни невронни модели могат да бъдат интегрирани в приложения и платформи за администриране на мрежовия трафик в ИКТ системи. Обхватът на представеното изследване позволява добавяне на аналитични модули в две направления:

- ❖ прилагане на техники за регресионно моделиране и статистическа диагностика по отношение на прогнозиране на вариациите и определяне на оптимални амплитудни нива на шума;
- ❖ включване на конвенционални и неконвенционални методи и алгоритми за оптимизация при търсене на оптимум при минимизация на целеви индекси на производителност на обслужвания трафик.

REFERENCE

- [1] Carlson A., Crilly P., Communication systems: An introduction to signals and noise in electrical communication. New York: McGraw-Hill Inc., 2010.
- [2] Samad N., Ishak A., Haruddin H. Introduction to communication systems. Kulim: Politeknik Tuanku Sultanah Bahiyah, 2021.
- [3] Balabanova I., Kostadinova S., Karapenev B., Georgiev G. Application of discriminant analysis for signals identification in communication systems. Journal of Engineering Science and Technology Review 2020;2020:1-8.
- [4] Balabanova IV, Kostadinova SS, Georgiev GI. Recognition of noises and noise speech signals by artificial neural networks. In: Proceedings of the second international conference on biomedical innovations and applications, vol. I, 2021, p. 119-122.
- [5] 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; 2020(1);1268-1277.
- [6] Chen A., Law J., Aibin M. A Survey on Traffic Prediction Techniques Using Artificial Intelligence for Communication Networks. Telecom 2021;2(4):518-535.
- [7] Rau F., Soto I., Zabala-Blanco D., Azurdia-meza C., Ijaz M., Ekpo S., Gutierrez S. A novel traffic prediction method using machine learning for energy efficiency in service provider networks. Sensors 2023;23(11):1-33.
- [8] 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;2023:1-28.
- [9] Andreoletti D., Troia S., Musumeci F., Giardano S. Network Traffic Prediction based on Diffusion Convolutional Recurrent Neural Networks. In: Proceedings of the second international workshop on network intelligence, vol. I, 2019, p. 1-6.
- [10] Balabanova I., Georgiev G. Traffic load prediction in Markov chains using artificial intelligence techniques. In: Proceedings of the third international conference on communications, information, electronic and energy systems, vol. I, 2022, p. 1-6.