

## РАЗПОЗНАВАНЕ НА ШУМОВЕ В КОМУНИКАЦИОННИ КАНАЛИ ПОСРЕДСТВОМ ИЗКУСТВЕНИ НЕВРОННИ МРЕЖИ

**Дионисия Даскалаки**  
Технически университет – Габрово  
dianisia\_d@abv.bg

## NOISE RECOGNITION IN COMMUNICATION CHANNELS BY ARTIFICIAL NEURAL NETWORKS

**Dionisia Daskalaki**  
Technical University of Gabrovo  
dianisia\_d@abv.bg

### Abstract

*In this paper, the processes about synthesis of artificial neural networks for noise recognition in communication channels were considered. Gaussian White Noise (GWN) and Periodic Random Noise (PRN) as well as digital signals with the presence of these noises are objects of simulation investigation. Accuracy, Mean Squared Error (MSE), regression and ROC curves and specific indicators for classification quality are analyzed. A different number of neurons in the hidden layers and type of output transfer function are evaluated. The accuracies more than 90.00 % were observed about the test signals.*

**Keywords:** noise recognition; GWN; IFN; artificial neural networks.

### ВЪВЕДЕНИЕ

Възникналите шумове в каналите за връзка при предаване на сигнали водят до съществени изменения в тяхната форма, независимо дали са аналогови или цифрови.

Изследванията по отношение на обработката и анализа на сигнали в комуникационните системи в различни сфери на индустрията основно са свързани с разпознаване на речеви, звукови или биомедицински сигнали в канали, представляващи преносна среда с наличие на шумове. Инструменти, които са прилагат за идентификация, са Deep Neural Networks (DNN), Скрипти модели на Марков, Multivariate Analysis of Variance (MANOVA), Multi-layer Perceptrons и други [1-4].

Други изследвания относно процесите по оценяване и редуциране на шумове в комуникационните системи се базират на специализирани подходи и алгоритми, между които могат да бъдат посочени:

- Independent Component Analysis (ICA) и Recursive Least Squares (RLS) в системите за разпознаване на реч;
- Support Vector Machine (SVM), k-means, k – Nearest Neighbors (k-NN) в оптичните комуникации;
- DNN и Convolutional Neural Networks (CNN) в OFDM и TDMR системи [5-8].

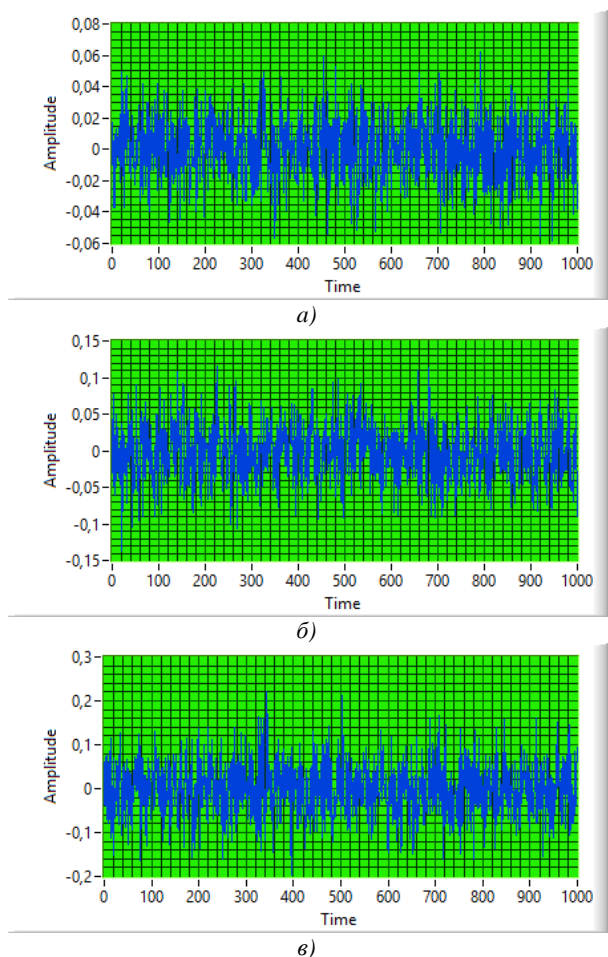
В доклада са представени част от резултатите при анализ и оценка на feed-forward backpropagation невронни мрежи при обучение с Levenberg-Marquardt алгоритъм при разпознаване на симуларани:

- типове шум – GWNs (клас №1) при вариращо стандартно отклонение и PRNs (клас №2) с променлива спектрална амплитуда;
- правоъгълни сигнали с наличие на GWN при различни стандартни отклонения на шума (клас №1) и PRN с промяна на спектралната амплитуда (клас №2), разпространени в ка-

налите за връзка в различни по архитектура, функционалност и предназначение комуникационни системи.

## ИЗЛОЖЕНИЕ

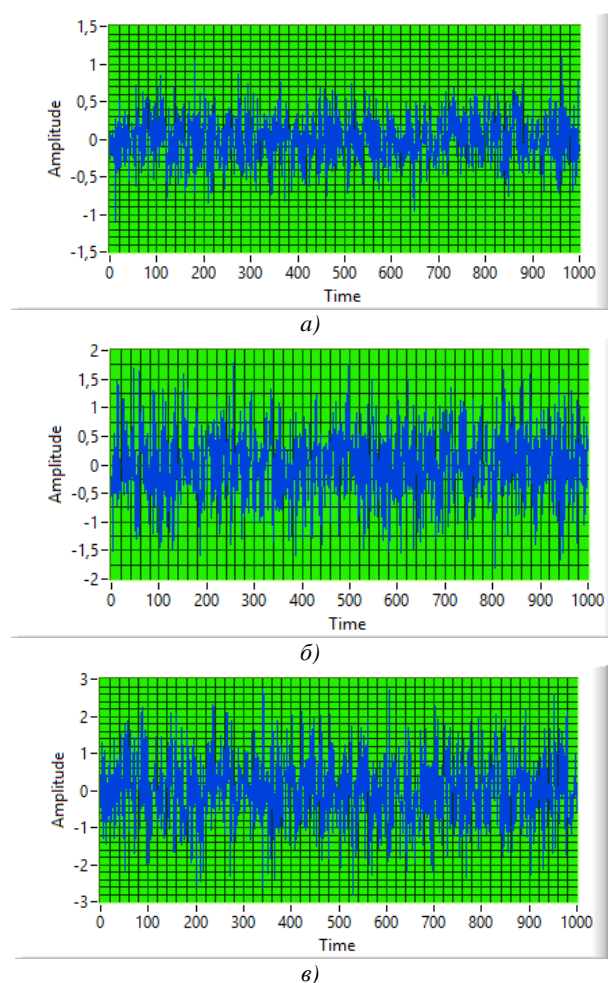
На фиг. 1 и фиг. 2 са дадени осцилограми на получените в симулационна среда LabVIEW групи шумове при фиксирани идентични стойности на стандартното отклонение за GWN и спектралната амплитуда при PRN, съответно 0.02, 0.04 и 0.06. Въз основа на експерименталните сигнали по аналогия на посочените нива на симулационните параметри е формирана информационна извадка включваща три информативни признака от 2000 наблюдения (GWNs - 1000 еталона, и PRNs - 1000 еталона).



Фиг. 1. Осцилограми на GWN при стандартно отклонение а) 0.02, б) 0.04 и в) 0.06

Извършено е обучение на изкуствени невронни мрежи за разпознаване на GWNs и PRNs при задаване на линейна и тангенсигмоидална функции на активация в изходните слоеве при 70 % от данните във входния набор. Резултатите от изследване-

то са обобщени в таблица 1 и таблица 2. Съдържанието на таблиците се свързва с изменения на точността и средноквадратичната грешка в границите от 5 до 20 скрити неврона.



Фиг. 2. Осцилограми на PRN при спектрална амплитуда а) 0.02, б) 0.04 и в) 0.06

Таблица 1. Резултати при разпознаване на GWNs и PRNs с изкуствени невронни мрежи с линейна изходна активационна функция


Скрити неврони	Точност, %	Средноквадратична грешка
5	94.0	0.0441
6	97.0	0.0310
7	97.7	0.0255
8	97.3	0.0284
9	98.3	0.0224
10	97.3	0.0282
11	99.7	0.0201
12	98.0	0.0265
13	97.3	0.0256
14	98.3	0.0251
15	100.00	0.0118
16	99.7	0.0188
17	98.3	0.0235
18	99.3	0.0170
19	99.0	0.0173
20	98.7	0.0219

**Таблица 2.** Резултати при разпознаване на GWNs и PRNs групи сигнали с изкуствени невронни мрежи с тангенс-сигмодална изходна активационна функция

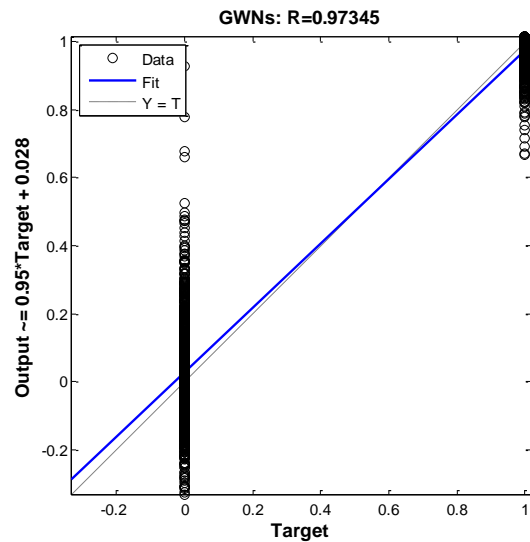
Скрити неврони	Точност, %	Средноквадратична грешка
5	99.3	0.0078
6	99.3	0.0115
7	99.0	0.0065
8	100.0	0.0074
9	98.7	0.0102
10	98.3	0.0115
11	99.3	0.0107
12	98.7	0.0121
13	100.00	0.0021
14	98.7	0.0126
15	99.3	0.0069
16	99.7	0.0091
17	99.7	0.0069
18	98.7	0.0140
19	99.7	0.0130
20	98.3	0.0137

При линейна активация са регистрирани минимална 98.3% и максимална 100.0 % точност при 5 и 15 междинни неврона. Грешката варира от 0.0118 при 15 до 0.0441 при 5 скрити неврона. По отношение на тангенс-сигмодална изходна активация е наблюдавана най-ниска точност 98.3 % при 10 и 20 скрити невронни единици, докато най-високата 100.0 % е достигната при 8 и 13. При втория критерии за качество е констатирано изменение от 0.0021 до 0.0140, съответно при 13 и 19 неврона в междинния слой.

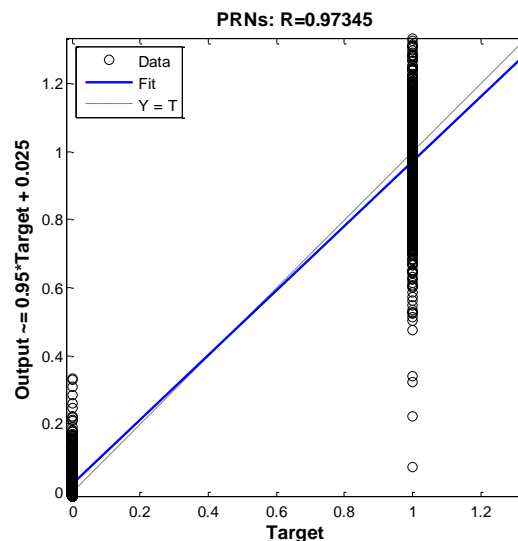
Откроява се тенденция на преимущество на тангенс-сигмодалната пред линейната активационна функция предвид регистрираните по-ниски стойности на MSE. На фиг. 3 са дадени селектираните мрежи при 15 и 13 с най-добри показатели при двете функции - линейна и тангенс-сигмодална.



**Фиг. 3.** Избрани невронни мрежи за разпознаване на GWNs и PRNs при изходна а) линейна и б) тангенс-сигмодална активационна функция



а)




б)

**Фиг. 4.** Зависимости за изходите на селектираната мрежа за разпознаване на GWNs и PRNs при изходна линейна активационна функция

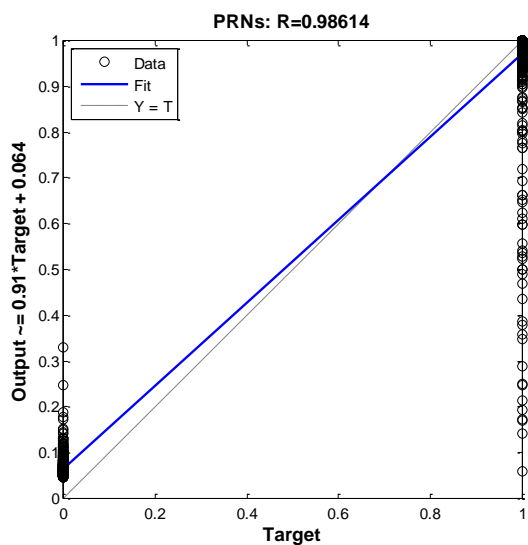
Направени са допълнителни процедури по оценка на синтезираните мрежи като са изведени зависимости за изходите – фиг. 4 и фиг. 5, и грешките от процеса на разпознаване с тяхно приложение на фиг. 6. Констатирано са високи нива на корелационните коефициенти, както следва за:

- „GWNs“ –  $R = 97345$  и  $R = 98919$  за мрежа с линейна и тангенс-сигмодална функция;
- „PRNs“ -  $R = 97345$  относно мрежата с линейна и  $R = 98614$  за тази с тангенс-сигмодална изходна функция.

Забелязва се по-високата степен на R при втората тестова архитектура, потвърждаващо установената тенденция между използваните типове активации на изхода. Налице е добро групиране на данните.



a)




б)

**Фиг. 5.** Зависимости за изходите на селектираната мрежа за разпознаване на GWNs и PRNs при изходна тангенс-сигмоидална актиционна функция


Установени са удовлетворяващи интервали на вариране на грешките (разлики между целевите и калкулираните от невронните мрежи резултати от -0.5 до 0.5) относно данните от тестовата извадка. Във връзка с мрежата при линейна изходна активация, показателя се изменя от -0.4753

до 0.4753, докато при тази с тангенс-сигмоидална, респективно от -0.2816 до 0.1902.

На следващ етап бяха симулирани правоъгълни сигнали с добавени GWN и PRN при нива на конфигурационните параметри 0.02, 0.04 и 0.06. Техните осцилограми са представени на фиг. 7 и фиг. 8.




a)

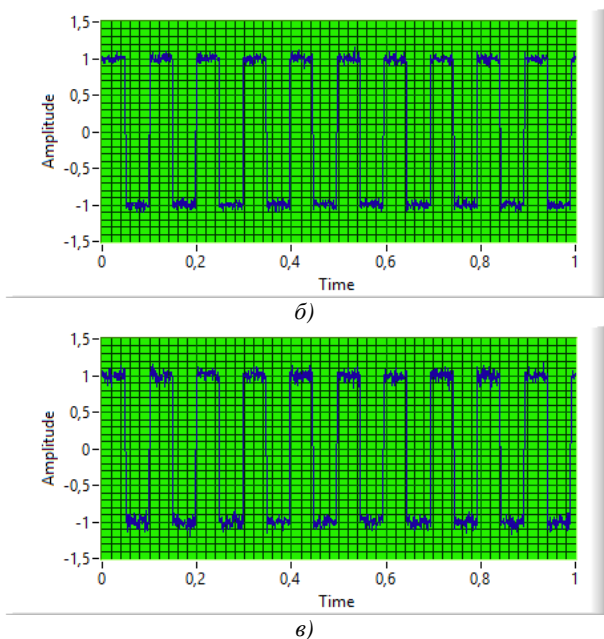


б)


**Фиг. 6.** Грешки за синтезираните невронни мрежи за разпознаване на GWNs и PRNs при изходна а) линейна и б) тангенс-сигмоидална актиционна функция



a)



**Фиг. 7.** Осцилограми на правоъгълни сигнали с GWN при стандартно отклонение на шума а) 0.02, б) 0.04 и в) 0.06




**Фиг. 8.** Осцилограми на правоъгълни сигнали с PRN при спектрална амплитуда на шума а) 0.02, б) 0.04 и в) 0.06

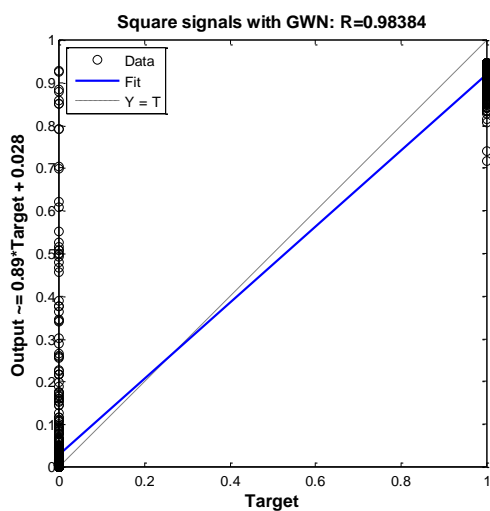
В таблица 3 са обобщени резултатите във връзка с архитектури с изходна тангенс-сигмодална функция на активация. Анализът и оценката са направени при същия диапазон на вариации на междинните неврони. Констатирано е минимално показание за точността 91.7 % при 5 скрити неврона, като за останалата по-голяма част от тестовия интервал критерия се изменя от 97.7 % при 12 до най-високата си стойност 100.0% при 17 неврона. Нивата на средноквадратичната грешка варират от 0.0186 до 0.0049 при 12 и 17 неврона в скрития слой с изключение на регистрираната MSE = 0.0608 при 5 междинни неврона. Фигура 9 онаглежда избраната невронна мрежа с 17 междинни неврона за идентификация на правоъгълните сигнали с наличие на шумове.

**Таблица 3.** Резултати при разпознаване на правоъгълни сигнали с GWN и PRN с изкуствени невронни мрежи с тангенс-сигмодална изходна активационна функция

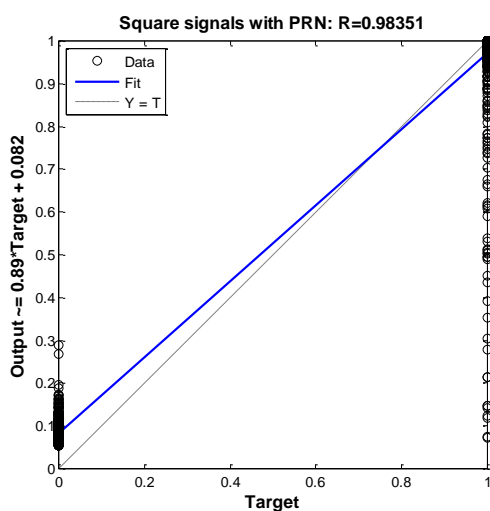
Скрити неврони	Точност, %	Средноквадратична грешка
5	91.7	0.0608
6	99.0	0.0076
7	99.3	0.0072
8	99.00	0.0084
9	98.3	0.0142
10	98.0	0.0162
11	99.3	0.0063
12	97.7	0.0186
13	98.3	0.0158
14	98.3	0.0144
15	99.0	0.0117
16	99.7	0.0057
17	100.0	0.0049
18	99.7	0.0171
19	99.0	0.0136
20	98.7	0.0159



**Фиг. 9.** Избрана невронни мрежа с изходна тангенс-сигмодална активационна функция за разпознаване на правоъгълни сигнали с GWN и PRN




a)



б)

**Фиг. 10.** Зависимости за изходите на селектираната мрежа с изходна тангес-сигмоидална актиционна функция за разпознаване на правоъгълни сигнали с GWN и PRN



**Фиг. 11.** Грешки за синтезираната невронна мрежа с тангес-сигмоидална актиционна функция за разпознаване на правоъгълни сигнали с GWN и PRN

Зависимостите на фиг. 10 показват добро сходство между пресметнатите и целевите резултати с високи нива на корелация, както следва  $R = 0.98384$  за сигнали с GWN и  $R = 0.98351$  за сигнали с PRN. Грешките за селектираната невронна мрежа на фиг. 11 попадат в интервала от  $-0.3861$  до  $0.3455$ .

## ЗАКЛЮЧЕНИЕ

Синтезирани са архитектури на изкуствени невронни мрежи за разпознаване на симулационни шумове с максимална достигната точност при линейна и тангес-сигмоидална функция на активация в изходните слоеве. Сравнително по-добри показатели са регистрираните при втория тип, използван като базова функция при изследване на задачата за идентификация на правоъгълни сигнали с присъствие на разгледащите шумове. Тук отново е постигнато коректно разпознаване на тестовите сигнали.

Представените резултати дават основание за продължаване на работата по изследването при анализ и оценка на шумове и сигнали с добавени шумове в реални комуникационни системи.

## REFERENCE

- [1] Vikramjit M., Franco H., Bartels Ch., Hout J., Gracieren M., Vergyri D. Speech recognition in unseen and noisy channel conditions, IEEE International Conference on Acoustics, Speech and Signal Processing, 2017, pp. 5215-5219.
- [2] Rawool V., Detection of Auditory signals in quiet and noisy backgrounds while performing a visuo-spatial task, Noise & Health, vol. 18(85), 2016, pp. 283-287.
- [3] Valenti M., Tolenti D., Vesperini F., Principi E. A neural network approach for sound event detection in real life audio, European Signal Processing Conference, 2017, 2823-2827.
- [4] Krishna G., Tran C., Yu J., Tewfik A. Speech recognition with no speech or with noisy speech, International Conference on Acoustics, Speech and Signal Processing, 2019, pp. 1019-1094.
- [5] Shrawankar U., Thakare V., Noise estimation and noise removal techniques for speech recognition in adverse environment, International Federation for Information Processing, 2010, pp. 336-342.
- [6] Avendano F., Soto A., Gonzalez N., Serafino G., Ghelfi P., Bogoni A., Machine learning

techniques for noise analysis in optical systems, *Intelligent System and Computing*, 2019, pp. 1-15.

[7] Hasan A., Shongwe Th., Impulse noise detection in OFDM communication system using machine learning ensemble algorithms,

*Advances in Intelligent Systems and Computing*, 2017, pp. 1-9.

[8] Fan C., Yuan X., Zhang Y., CNN-based signal detection for banded linear systems, *IEEE Globecom*, 2018, pp. 1-27.