

CLASSIFICATION OF TELETRAFFIC SYSTEMS WITH APPARENT LOSSES BY ARTIFICIAL NEURAL NETWORK

Georgiev Georgi, Balabanova Ivelina, Technical university of Gabrovo, givanow@abv.bg,
ivstoeva@abv.bg

Abstract: The artificial neural network is a system of processing elements, provisionally called artificial neurons due to the analogy with biological human neurons. Artificial neurons convert incoming input and output signals from that send to the elements that have links with certain weights. The transformation is performed by initially forming the aggregate signal input to the respective neuron, and then through the particular network function of the activation, the resulting aggregate input signal is transformed into an output of this processing unit.

Keywords: classification method, validation, teletraffic, Artificial Neural Networks, back propagation of error


КЛАСИФИЦИРАНЕ НА ТЕЛЕТРАФИЧНИ СИСТЕМИ С ЯВНИ ЗАГУБИ ПОСРЕДСТВОМ ИЗКУСТВЕНА НЕВРОННА МРЕЖА

Георги Георгиев, Ивелина Балабанова, Технически университет - Габрово,
givanow@abv.bg, ivstoeva@abv.bg

Абстракт: Изкуствената невронна мрежа (Artificial neural network) представлява система от обработващи елементи, условно наричани изкуствени неврони поради аналогията с биологичните човешки неврони. Изкуствените неврони преобразуват постъпващи входни и формират изходни сигнали, които изпращат към елементите, с които имат връзки с определени тегла. Преобразуването се извършва като първоначално се формира сумарния входен сигнал до съответния неврон, след което посредством специфичната за мрежата функция на активация, полученият сумарен входен сигнал се трансформира в изходен за този обработващ елемент.

Ключови думи: класификационен метод, валидиране, телетрафик, изкуствени невронни мрежи, обратно разпространение на грешката

Най-често при решаването на задачи за разпознаване се използва трислойна архитектура на изкуствените невронни мрежи, мрежа с един входен, един междинен (скрит) слой и изходен слой, с обратно разпространение на грешката. В скрития слой на мрежата се използва тангенс-сигмоидална, а в изходния линейна функция на преобразуване. Основно предимство на подхода с обратно разпространение на грешката се свързва с процеса на обновяване на мрежовите тегла на всяка итерация с цел минимизиране на грешката между целевия и пресметнатия резултат на изхода на невронната мрежа.



Фиг.1. Трислойна архитектура на изкуствена невронна мрежа

Предимства:

- ✓ високи скорост и гъвкавост при обработка на данни;
- ✓ адаптивност към всеки тип задача след подходящо обучение, моделиране на различни процеси;
- ✓ разпределена паралелна обработка на входните данни;
- ✓ устойчивост спрямо нивото на шум във входните данни;
- ✓ способност за детектиране на всички възможни, комплексни непараметрични зависимости между входните и изходни променливи;
- ✓ способност за самообучение за създаване на обобщение (способността на мрежата за получаване на обоснован резултат на основата на данни, които не са участвали в процеса на обучение) и др.

Недостатъци:

- ✓ необходимост от повторно дефиниране и обучение при включване на нови входни параметри;
- ✓ големи по структура невронни мрежи изискват повече процесорно време и ресурси;
- ✓ достоверността при оценяване и прогнозиране е зависеща от това доколко мрежата е правилно обучена и др.

Приложение:

- ✓ инженерна дейност - разпознаване на образи; обработка, анализ и извличане на характеристики от образи; идентификация и управление на различни обекти;
- ✓ приложна математика – апроксимация на функция, оптимизационни задачи с и без ограничения и др.;
- ✓ статистика – модели на нелинейна регресия и класификация на данни;
- ✓ бизнес – контрол на индустриални процеси, проучвания на потреблението, прогнозиране на продажби, управление на риска, счетоводство и финансов анализ и др.;
- ✓ медицина – разпознаване на заболявания, моделиране и диагностика на сърдечно-съдовата система и др.

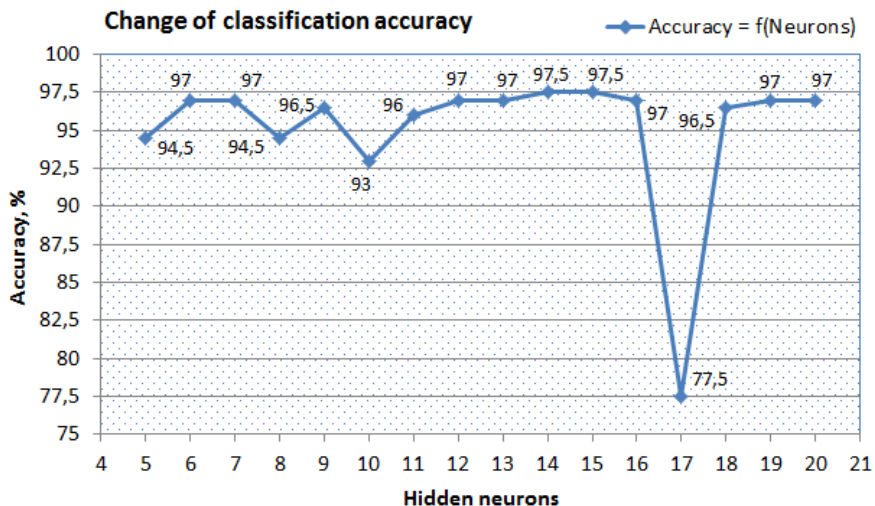
Предложена е трислойна архитектура на изкуствена невронна мрежа с обратно разпространение на грешката за разпознаване на телетрафични системи с явни загуби при приета вероятност за загуби B от 0.05 . Използвани са тангенс-сигмоидална и линейна функции на активация в скрития и изходен мрежови слоеве. Обучението на невронната мрежа е извършено по алгоритъма на Levenberg-Marquardt в среда на продукта Matlab. Входният набор от данни, съдържащ 200 наблюдения, е базиран на стойности на две независими променливи, съответно брой на информационните канали n и постъпващ трафик A (изчислен по формулата на Ерланг). В процентно съотношение

данните са разделени на 60% за обучение, 20% за валидиране и 20% за тестване на невронната мрежа. Извършена е тяхна нормализация в интервала от -1 до 1. Формирани за пет класа телетрафични системи в различен диапазон на информационните канали n . За всеки клас са използвани отделен неврон в изходния мрежови слой и дискретна кодова комбинация като посредством позицията на единицата се указва принадлежността на конкретна телетрафична система. В таблица 1 са представени входните, изходни и обучаващи мрежови параметри.

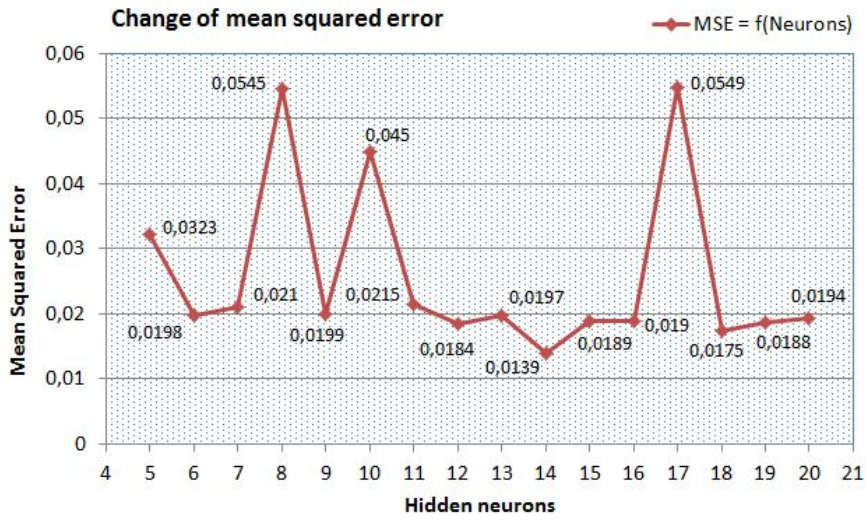
Входни параметри	Изходни параметри		Обучаващи параметри
	Етикет на класа	Кодови комбинации	
1. Брой канали n . 2. Постъпващ трафик A , изчислен по формулата на Ерланг.	1. Teletraffic system №1 (n = 1 to 40).	1 0 0 0 0	<i>Epochs</i> (максимален брой обучаващи цикли): 1000 <i>Show</i> (обучаващи цикли между показванията): 25 <i>Goal</i> (минимална средноквадратична грешка): 0.01 <i>Lr.</i> (скорост на обучение): 0.05 <i>Min grad.</i> (минимална големина на градиента): 1-e05
	2. Teletraffic system №2 (n = 41 to 80).	0 1 0 0 0	
	3. Teletraffic system №3 (n = 81 to 120).	0 0 1 0 0	
	4. Teletraffic system №4 (n = 30 to 1200).	0 0 0 1 0	
	5. Teletraffic system №5 (n = 1230 to 2400).	0 0 0 0 1	

Таблица 1. Входни, изходни и обучаващи мрежови параметри

Експериментирано е с броя на невроните в скрития мрежови слой в диапазона от 5 до 20 и са изследвани измененията на класификационната точност и средноквадратичната грешка, показани на фиг.2. Основен критерий при търсене на оптимална структура на изкуствена невронна мрежа е комбинацията от най-висока точност и минимална средноквадратична грешка. Желаните нива на указаните параметри, съответно от 97.50% и 0.0139, са постигнати при 14 скрити неврона. На фиг.3 е представена архитектура на селектирана невронна мрежа за разпознаване на телетрафични системи с явни загуби.




а) изменение на класификационната точност




б) изменение на средноквадратичната грешка

Фиг.2. Изменение на класификационната точност а) и средноквадратичната грешка б)




Фиг.3. Архитектура на изкуствена невронна мрежа за разпознаване на телетрафични системи с явни загуби



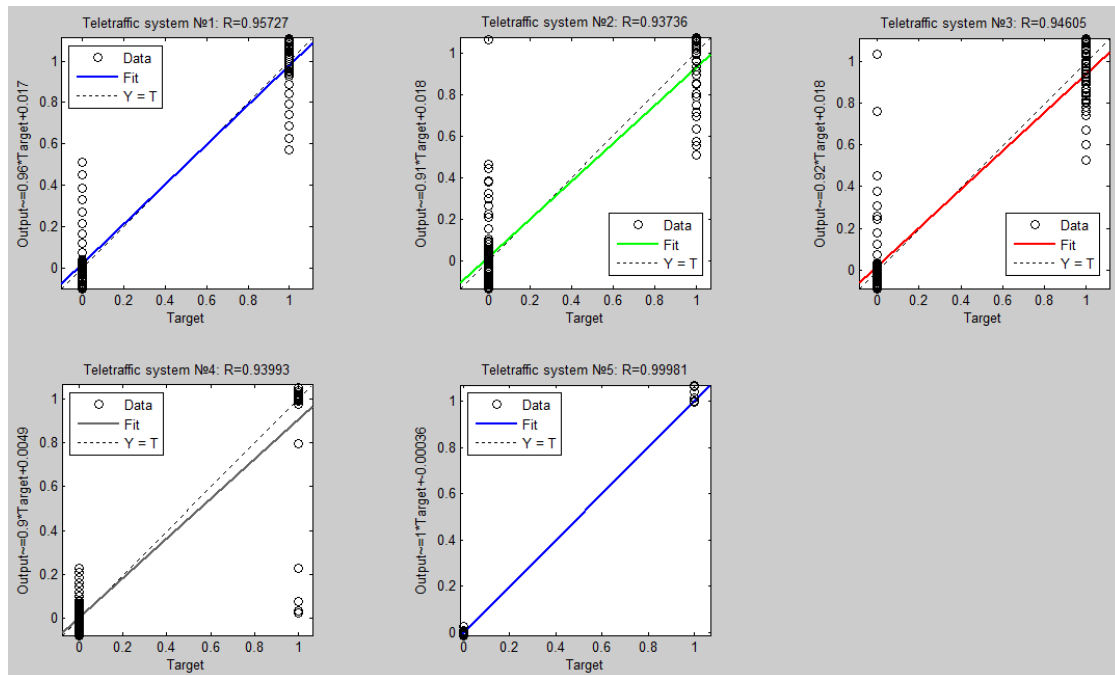
Фиг.4. Средноквадратична грешка за процесите на мрежово обучение, валидиране и тестване – оценка на мрежовата производителност

На фиг.4 е показано изменението на *средноквадратичната грешка* за процесите на обучение, валидиране и тестване на невронната мрежа. Не се наблюдават проблеми при мрежово обучение. Кривите на валидиране и тестване имат подобен и намаляващ характер на изменение. Индикация за възможно преобучение би била наличието на значително нарастване на тестовата преди нарастване на валидиращата крива. Най-добра производителност при валидиране от 0.0064373 е достигната при 146-та итерация.




Фиг.5. Състояние на мрежовото обучение

Изменяята на *градиента* и променливата *mu*, участваща при определяне на промяната на стъпката на достигане до неговия минимум (стъпката на изменение на средната квадратична грешка), спрямо итерациите на обучение на невронната мрежа са показани на фиг.5. Параметрите са достигнали стойности от 0.0035987 и 0.001 при 146-та итерация. Посредством променливата *val fail* са указвани обучаващите цикли, при които са настъпили нараствания на средноквадратичната грешка за процеса мрежово валидиране.



a)



б)

Фиг.6. Линейни регресионни зависимости за изходните целеви класове а) и процесите на обучение, валидиране и тестване на невронната мрежа б)

Формирани са линейни регресионни зависимости, разположени на фиг.6 а) за всяка класификационна група и б) за процесите на обучение, валидиране и тестване на невронната мрежа. Прекъснатата и плътна линии съответстват на тези на съвпадение и най-добра линейна регресия между изходните и целеви мрежови резултати. В таблица 2 се съдържат данни за параметрите наклон m и отрязък b на най-добра линейна регресия и корелационните коефициенти R за всеки изходен неврон, чиито стойности в идеалния случай биха били 1 , 0 и 1 . Получените стойности на указаните параметри потвърждават добро приближение и линейна връзка между изходните и целеви параметри на невронната мрежа. Най-добро групиране на данните около дискретните нива, дефиниращи класификационна принадлежност, се наблюдава при пета група и тестване на мрежата. При първите три изходни неврона и мрежово обучение като цяло групирането е добро. Забелязват се точки, за които има по-слабо и слабо за отделни наблюдения приближение между изходните и целеви резултати.

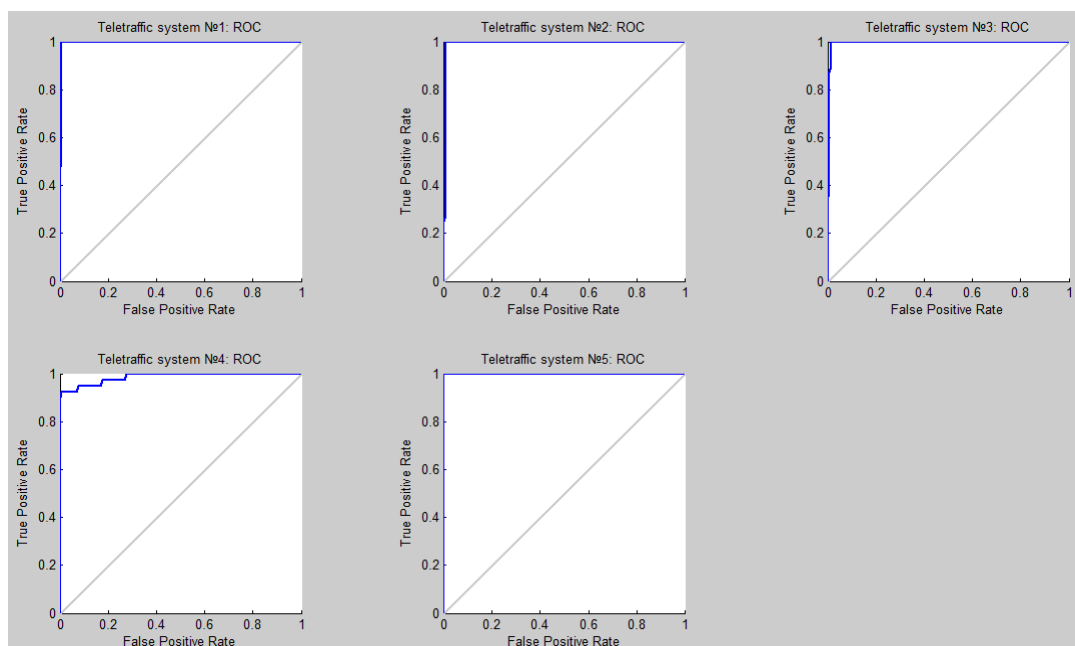
Изход	Наклон на най-добрата линейна регресия m	Отрязък на най-добрата линейна регресия b	Корелационен коефициент R
1	0.9643	0.0170	0.9573
2	0.9119	0.0182	0.9374
3	0.9213	0.0180	0.9460
4	0.9037	0.0049	0.9399
5	1.0050	-0.0004	0.9998

Таблица 2. Параметри на линейна регресия

Output Class	1	2	3	4	5	
1	40 20.0%	1 0.5%	0 0.0%	1 0.5%	0 0.0%	95.2% 4.8%
2	0 0.0%	39 19.5%	0 0.0%	1 0.5%	0 0.0%	97.5% 2.5%
3	0 0.0%	0 0.0%	40 20.0%	2 1.0%	0 0.0%	95.2% 4.8%
4	0 0.0%	0 0.0%	0 0.0%	36 18.0%	0 0.0%	100% 0.0%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	40 20.0%	100% 0.0%
	100% 0.0%	97.5% 2.5%	100% 0.0%	90.0% 10.0%	100% 0.0%	97.5% 2.5%
	1	2	3	4	5	


Фиг.7. Матрица на коректните и некоректни класификации

Матрицата, представена на фиг.7, показва коректно класифициране на наблюденията, отнасящи се към телетрафични системи №1, №3 и №5. Едно наблюдение от система №2 е определено като принадлежащо към №1. Четири наблюдения от система №4 са некоректно класифицирани, съответно две са отнесени към трета класификационна група и останалите към системи №1 и №2. Ако класификацията изцяло е протекла коректно, то всички наблюдения трябва да бъдат разположени от горния десен към долния ляв ъгъл по диагонала на матрицата, а останалите матрични елементи да имат стойност нула. Постигната е обща точност на класифициране от 97.50% и точност по класове, съответно от 100.00% за телетрафични системи №1, №3 и №5, от 97.50% за №2 и 90.00% за система №4.



Фиг.8. ROC анализ – оценка на качеството на класификатора

На фиг.8 са показани диаграми за оценка на качеството на класификатора, изобразяващи зависимостта „чувствителност” спрямо „специфичност” или коректно спрямо некоректно класифицирани наблюдения за всяка изходна група. Построяването им е базирано на получената матрица на класификация. Като мярка за оценка на работата на класификационния модел се използва площта под ROC кривата, приемаща стойности между 0 и 1. Колкото по-голяма е площта, т.е траекторията на кривата повече се доближава до направление от долен към горен ляв ъгъл към горен десен ъгъл, толкова класификаторът се определя като по-добър. Най-високо качество при класифициране на данни посредством изкуствената невронна мрежа е постигнато при телетрафични системи №1, №3 и №5, последвани от това при №2 и на последно място от №4.



Фиг. 9. Абсолютна мрежова грешка

Абсолютната мрежова грешка, варираща в границите от -0.9768 до 1.0636, е представена на фиг.9. Грешката е калкулирана като разлика между изходните мрежови и целеви резултати. Едва забележими нива на нейно изменение се наблюдават при телетрафична система №5. При останалите класификационни групи, за голяма част от наблюденията получените нива са в приемливия диапазон от -0.5 до 0.5, само за отделни наблюдения са налице пикови стойности на грешката.

Получените тегловни матрици и матрици на отместванията за скрития и изходен слоеве на предложената невронна мрежа са обозначени с формули от (1) до (4):

$$\begin{array}{ll}
 -6.2737 & -4.2876 \\
 -4.9745 & -4.1351 \\
 5.7886 & 9.2411 \\
 1.7627 & -5.6403 \\
 -29.1849 & -33.2037 \\
 -18.0473 & -18.1730 \\
 28.0108 & 26.5547 \\
 -11.6645 & -18.4438 \\
 -53.1816 & -43.9028 \\
 -13.1171 & 21.8680 \\
 38.9575 & 33.8694 \\
 17.7502 & 19.6550 \\
 3.3758 & -3.9760
 \end{array}$$

(1)

1.8475
 0.8134
 -0.5079
 -4.2253
 -58.5888
 0.4966
 -0.6342
 -27.0028
 -90.9449
 -33.4707
 70.4791
 35.4619
 4.5528
 -4.1783 (2)

Columns 1 through 11

0.0217 -0.0384 -0.0106 -2.0240 1.1944 0.0001 0.0004 0.1995 0.0907 -9.1062 -4.4178
 0.0057 -0.0158 -0.0168 0.6757 -19.4352 -0.0118 -0.0056 -0.6950 9.0887 0.2550 5.7789
 -0.0623 0.1183 0.0537 -0.0399 3.0970 0.0145 0.0051 1.4435 -3.7517 1.5307 0.4203
 0.5401 -1.8431 -2.6584 2.1203 15.0564 -5.2161 -4.8530 -0.9606 -5.3918 7.3527 -1.7636
 -0.5272 1.8191 2.6458 1.1990 -0.0945 5.2216 4.8587 0.0001 0.0473 0.1794 0.0348

Columns 12 through 14

-3.8256 2.2809 6.3343
 -16.9005 -1.0533 -1.6261
 1.5855 -1.4361 -2.5501
 19.0909 -2.6271 -4.4223 (3)
 0.0656 -1.3813 -4.0690

1.6455
 -0.5619
 -1.8281
 -0.9533
 -1.4499 (4)

- ✓ където (1) и (2) са тегловната матрица $iw\{1,1\}$ и матрицата на отместванията $b\{1\}$ за скрития слой, а (2) и (4) са тегловната матрица $lw\{2,1\}$ и матрицата на отместванията $b\{2\}$ за изходния мрежови слоеве.

Заклучение

Предложена е трислойна архитектура на изкуствена невронна мрежа, обучена по алгоритъма на обратно разпространение на грешката, за класифициране на телетрафични системи с явни загуби. Изследвани са вариациите на средноквадратичната грешка и класификационната точност с промяна на невроните в скрития мрежови слой. Избрана е архитектура с 14 скрити неврона, при която са постигнати средноквадратична грешка от 0.0139 и точност на класификация от 97.50%. Приложен е технически подход при дефиниране на класификационни групи посредством отделни изходни неврони и дискретни кодови комбинации. Подходът е сравнително по-рядко използван, за разлика от кодирането чрез един неврон в изходния

мрежови слой и задаване на принадлежността на целевите класове с променлива с различни нива. Полученият висок процент на точност потвърждава успешното решаване на поставената класификационната задача и приложимост на апарата на изкуствените неврони при определяне на принадлежността на телетрафични системи с явни загуби.

References:

- [1] Мирчев М. Телетрафично проектиране., Изд. “Нови Знания”, София, 2002.
- [2] Chen Ch., Shih J.-Sh., Multi-Channel Piezoelectric Quartz Crystal Sensor with Principal Component Analysis and Back-Propagation Neural Network for Organic Pollutions from Petrochemical Plants. *Jornal of Chinese Chemical Society*, 2008, 55, p.979-993.
- [3] Huiling T., Guangzhong X., Yadong J., Gas Identification Using Gas Sensor Array and Self Organization Competitive Neural Network, Ministry of Education The Key Laboratory of Novel Transducers, China.
- [4] Shih J., Hsu H., Multi-Channel Surface Acoistic Wave (SAW) Sensor Based on Artificial Back Propagation Neural (BPN) and Multivariable Linear Regression Analysis (MLR) for Organic Vapours. *Jornal of Chinese Chemical Society*, 2007, 57, p.401-410.
- [5] Artificial Intelgence: Foundations of Computational Agents. Neural Networks, 2010. (http://artint.info/html/ArtInt_183.html#nnet-ex).