

ВЪЗМОЖНОСТИ ЗА ПРИЛОЖЕНИЕ НА ИЗКУСТВЕНИ НЕВРОННИ МРЕЖИ (ИНМ) ПРИ ТРАНСПОРТНОТО ПЛАНИРАНЕ

POSSIBILITIES FOR APPLICATION OF ARTIFICIAL NEURAL NETWORKS (ANN) IN TRANSPORTATION PLANNING

ас.маг.инж. Беров Т.¹,
ВТУ"Т.Каблешков" - София¹
E-mail: tberov@vtu.bg;

Abstract: The object of this paper is the implementation of the ANN model for modeling of both trip generation and trip distribution, and mode choice - steps of the classic four-step transport model. The ANN model is implemented on MS Excel spreadsheet and Solver add-in. Algorithm on how to build neural network model with Excel is explained step by step. The factors for the relevant steps and architecture of the respective neural networks are defined. The model is focused on the two competing public passenger transport services – rail services and bus services.

KEYWORDS: PUBLIC TRANSPORTATION; TRIP GENERATION, ARTIFICIAL NEURAL NETWORKS, EXCEL

1. Въведение

През 1943 г. Маккулок и Питс предлагат модел на неврон като двоичен прагов елемент. С това се слага началото на моделирането на изкуствени невронни мрежи (ИНМ), намиращи приложение в производственото планиране и управление на процеси, система за идентификация, проверка и прогнозиране и др.

Невронните мрежи са единият от основните методи за обучение в компютърната интелигентност. Полученото знание в невронните мрежи се представя с числените стойности на теглата в структурните връзки. Характерно приложение на ИНМ е за апроксимация на нелинейна функция като не се нуждаят от предположение за зависимости и независими променливи. Тази им способност дава възможност за приложение при моделиране на транспортни процеси.

Транспортните инженери често се сблъскват с въпроса как да се извлече достатъчна информация от оскъдни отчетни или от изследваните данни. Общият подход е да се създаде модел, който описва поведението на наблюдаваното явление, при което данните се използват за калибриране / валидиране.

При транспортното планиране изключително прилаган е класически четиристъпков транспортен модел: *Генериране на пътуванията* (trip generation); *Разпределяне на пътуванията* (trip distribution); *Избор на вид превоз* (mode choice) и *Полагане на движението* (route flow assignment). Получените крайни резултати са строго зависими от качеството на използваните данни. При отделните стъпки на този модел обикновено се използват класическите подходи: методът на линейната регресия при моделиране на генерираните пътувания; най-често използваните методи за моделиране на дистрибуцията на пътуванията са така наречените гравитационни модели; изборът между железопътния и автобусния транспорт се моделира чрез двучленен логит модел.

Предмет на настоящия материал е начина на приложение на модела ИНМ при две от стъпките на четиристъпковия модел за търсенето на транспортни услуги за превоз на пътници с обществен транспорт в Република България, за конкуриращите се два вида обществени превози, а именно железопътните и автобусните. Предложени са съответните структури ИНМ модели, които са реализирани чрез използване на Excel -> Solver като съответен инструментариум.

2. Описание на проблема

Използвани методи

Както бе посочено по-горе, широко използвани методи за генериране на произведени и привлечени пътувания е Метод на линейната регресия.

$$(1) \quad Y_i = a_0 + a_1 x_1 + \dots + a_n x_n$$

където Y_i е броя произведени (или привлечени) пътувания в зона i ; x_1, \dots, x_n са влияещите социално-

икономически и демографски фактори, характерни за зона i ; a_i са коефициенти, получени от регресионния анализ.

Най-често използваните методи за моделиране на дистрибуцията на пътуванията са така наречените гравитационни модели. Типична форма на модел за определяне на брой пътувания между двойка транспортни райони:

$$(2) \quad T_{ij} = A_i B_j O_i D_j f(c_{ij})$$

където A и B са множества от балансиращи коефициенти аналогични на тези от метода на Фурнес; O и D със съответните им индекси са броят породени и броят привлечени пътувания за дадените зони, $f(c_{ij})$ е функцията на възпиране. Тя има за цел да обясни неизгодите от едно пътуване между дадените зони, като най-често се използват експоненциални, показателни или смесени функции на „обобщените разходи“ за пътуване (парични разходи за гориво, билети, паркинг, разходи на време за пътуване, чакане, прекачване превърнати във величини с една и съща мерна единица).

Широко използван подход за *Избор на вид превоз* (също така и за *Разпределяне на пътуванията*) са логит модели. Те са модели за избор на една алтернатива измежду две и повече (discrete choice, mode choice). Изборът се основава на „полезността“, т.е. предполага се, че се избира тази алтернатива, която предлага най-висока полезност U_i :

$$(3) \quad U_{in} = U(S_n, X_{in}, \varepsilon)$$

където S_n е набор от характеристики, които описват взимания решение n , X_{in} е група економетрични данни, описващи алтернативите и ε е случаен елемент.

Приема се, че полезността е линейна функция на няколко наблюдаеми фактора, като всеки фактор k има и коефициент β_k , отразяващ тежестта, т.е. значението му в общата полезност:

$$(4) \quad U_i = \sum \beta_k \cdot X_{ik}$$

След определяне на полезността на всички Z конкурентни алтернативи, може да се пристъпи към търсене на вероятността всяка една от тях да бъде предпочетена от пътника:

$$(5) \quad P(1|Z) = \frac{e^{\mu \cdot U_1}}{\sum_{Z=1}^Z e^{\mu \cdot U_Z}}$$

Масщабния параметър обикновено е равен на единица, но неговото използване повишава точността на прогнозата, т.е. той служи за нормализация. При бинарен модел с две алтернативи:

$$(6) \quad P(1) = \frac{1}{1 + e^{-(u_1 - u_2)}}$$

където u_1 и u_2 са съответно полезностите на двете алтернативи.

Метод чрез ИНМ



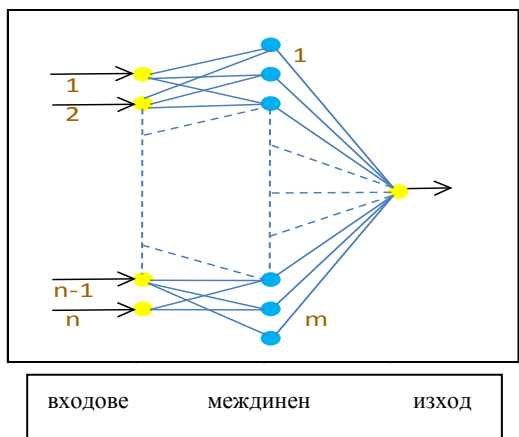
фиг.1 Схематично изобразяване на изкуствен неврон

Фигурата показва схематично представяне на изкуствен неврон, в които има две функции: сумата от претеглените входове и активираща функция. Първата функция просто агрегира претеглените входове и добива стойност I_j :

$$(7) \quad I_j = \sum_{i=1}^n w_{ij} \cdot x_j$$

където w_{ij} е съответното тегло, а x_j – стойността на съответния показател.

Втората част е филтър, който обикновено се нарича функция за активиране, посредством която се комбинират потоците сигнали. Често използвани функции за активиране са: Линейна, Прагова, Сигнум (Signum) и Логистична.



фиг.2 Архитектура на ИНМ (FFNN) ($n \times m \times 1$)

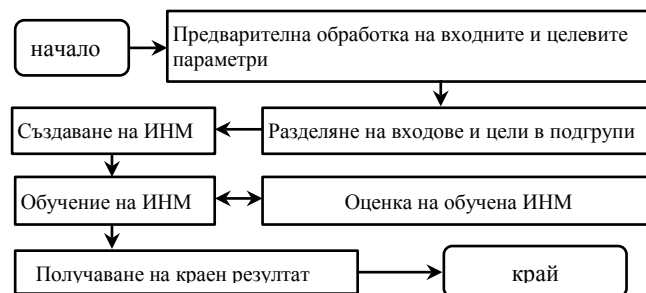
Невронни мрежи с обратно разпространение на грешката (FFNN)

Това са ИНМ с поне един скрит слой, при които съществуват връзки от всеки елемент от даден слой към всеки елемент от непосредствено следващия слой.

Двете най-съществени характеристики на невронните мрежи са: способност да се "учат" и способност да генерализират. Невронните мрежи изискват данните да се поддават на обучение. Обучението на системата се реализира чрез промяна в стойностите на тегловните коефициенти. За всяка връзка, има тегло w_{ij} , предназначена за нея. Коефициентите се променят в съответствие с избрания алгоритъм на обучение. След като мрежата е "обучена", тя трябва да се "захрани" с нови данни, които не са били използвани по време на нейното обучение. Това е своеобразен начин на тестване на невронната мрежа, за да се установи дали е в състояние да прогнозира неизвестните изходи или по-точно, способна ли е да генерализира.

Обучението е процес на адаптиране тежестите на връзките в изкуствената невронна мрежа, така че да се определи желания изходящ вектор, в отговор на стимулите, представени на входния буфер.

Най-използвания метод от последния тип е Алгоритъм за обучение с обратно разпространение на грешката (backpropagation), фиг. 3.



фиг.3 Алгоритъм за реализиране на ИНМ

3. Приложение на предложения алгоритъм

Детерминиране на модела ANN (архитектурата на невронната мрежа)

Има два въпроса, които трябва да бъдат взети предвид при определянето на модел ANN: неговата структура и параметрите, участващи в процеса на обучение. В нашият случай използваме многослойна, изцяло свързана невронна мрежа с право разпространение за определяне на разгледаните показатели за транспортно планиране. За нейната структура, трябва да определим броя на скритите слоеве, броя на невроните във всеки слой, броя и типа на връзките между тях.

• Структура на модела ANN

Най-лесно се определя броят на невроните във входящия и изходящия слой, тъй като всяка независима и зависима променлива се представя като отделен неврон. Възлов момент при разработването на една невронна мрежа е определянето броя на скритите слоеве и съдържащите се в тях неврони.

Способността на невронни мрежи за моделиране на входно-изходни параметри е пряко свързана с нейната структура. Може да се каже, че за моделиране взаимодействие и нелинейност, типичната мрежа се състои от един междинен слой между входящия и изходящия слоеве. Когато данните са прекъснати, са препоръчителни два междинни слоя. За разглеждания модел, е избрана невронна мрежа с един междинен слой, т.е. ще има три слоя при този ИНМ модел : входящ слой, междинен слой и изходящ слой.

• Параметри в процеса на обучение

• Определяне параметрите на невроните (активираща функция и начина на комбиниране на невроните)

FFNN с обратно разпространение на грешката използва логистична функция.

$$(8) \quad a_j(n) = \frac{1}{1 + e^{\sum a_i \cdot a_i + \theta_i(n)}}$$

където $a_j(n)$ е активиране на елемент j за итерация n и $\theta_j(n)$ е „прагова“ стойност на неврон j за итерация n .

• Избор на критерий за оценка на модела

Основната цел на алгоритъма на обучение с обратно разпространение на грешката е да се минимизира сумата на средната квадратичната грешка (Mean Square Errors (MSE)). Този измерител дава представа за качеството на невронната мрежа.

$$(9) \quad E = \frac{1}{n} \sum_{i=1}^n (y_i - x_i)^2$$

където y_i е желан резултат на i - я изходящ неврон и x_i е получен (обучен) резултат на i - я изходящ неврон.

3.1 Построяване на невронни мрежи чрез използване на Microsoft Excel

Реализирането на изградена ИНМ може да стане по няколко начина: MATLAB, Език за програмиране, готов модул, Excel и др. В настоящия материал е залегнало използването на

Excel и инструмента Solver (фиг.4). Използваните стъпки са както следва:

1. Подготовка на данни за обучение на ИНМ
 - определяне на входните и изходни параметри;
 - определяне на броя входове и изходи на ИНМ;
 - разпределяне на данните в групи (обучение, контрол, проверка);
 - скалиране на данните [0,1];
2. Определяне на архитектурата на ИНМ
 - определяне слоевете и невроните за всеки слой;
 - определяне на трансферната функция;
 - инициализиране стойностите на теглата и отклоненията;
 - въвеждане на формули за всички скрити неврони;
 - въвеждане на формули за изходящия неврон;
 - въвеждане на формули за $error^2$ и MSE.
3. Стартиране на Solver add-in
 - целева функция - min MSE;
 - извършване на минимизирането.
4. Обработка на получения резултат.
 - зареждане *графика* за изход и прогнозен резултат;
 - скалиране на прогнозирания изход;
 - записване на окончателните стойности на теглата и отместванията.

Определяне на параметри при транспортно планиране чрез ИНМ

Две от стъпките на традиционния четиристъпков транспортен модел са *генериране на пътуванията* и *избор на вид превоз*. Разгледано е използването на ИНМ модела за търсенето на транспортни услуги за превоз на пътници с обществен транспорт в Република България, за конкуриращите се два вида обществени превози, а именно железопътните и автобусните.

Генериране на пътуванията

Използвани фактори (както за изходящи, така и за входящи пътувания) са:

- числеността на населението, X1
- БВП на глава от населението, X2
- средна годишна работна заплата, X3
- цена на жилища, X4
- изход – съответните пътувания X5

Таблица 1: Параметри на модел ИНМ за Генериране на пътуванията

Брой на слоевете	3
Брой на невроните във входящия слой	4
Брой на невроните в междинния слой	6
Брой на невроните в изходящия слой	1
Активираща функция за междинния слой	Логистична функция
Активираща функция за изходящия слой	Логистична функция

Избор на вид превоз

В стъпката „модален сплит“ трябва да се разработи модел, отчитащ точно факторите определящи личния избор на вид транспорт за дадено пътуване. Тези фактори могат да се класифицират в три групи – такива, характеризиращи пътуващия (доходи, притежание на автомобил, семейно положение и др.), такива, характеризиращи пътуването (цел на пътуване, време от денонощието) и такива, характеризиращи условията на пътуването (парични и времеви разходи, честота на услугата, комфорт).

Приложен е модела ИНМ за два вида транспорт – железопътен (ЖТ) и автобусен (АТ). Входни параметри са съответно *времетрайване*, *цена за билет*, *честота на услугата* и *комфорт* за всеки от двата вида транспорт. Изходен параметър е $p_{ij}^{влак}$.

$$(10) \quad T_{ij}^{влак} = p_{ij}^{влак} \cdot T_{ij}$$

където T_{ij} е общия поток, съответстващ на дъгата (ij); $T_{ij}^{влак}$ е съответно общия влакопоток, а $p_{ij}^{влак}$ е дела на влакопотока.

Използвани фактори за *Избор на вид превоз* са:

- времетрайване - АТ, X1
- времетрайване - ЖТ, X2
- цена за билет - АТ, X3
- цена за билет - ЖТ, X4
- честота на услугата - АТ, X5
- честота на услугата - ЖТ, X6
- комфорт - АТ, X7
- комфорт - ЖТ, X8
- изход – пътувания ЖТ X9

Таблица 2: Параметри на модел ИНМ за Избор на вид превоз

Брой на слоевете	3
Брой на невроните във входящия слой	8
Брой на невроните в междинния слой	12
Брой на невроните в изходящия слой	1
Активираща функция за междинния слой	Логистична функция
Активираща функция за изходящия слой	Логистична функция

4. Резултати

На фиг. 4 е показан екрана на Excel за ИНМ за табл.1. Използвани са данни [1],[7] за прогнозиране на пътувания за сухоземен транспорт.

Използвани означения при реализация чрез Excel:

Слой 1 - Входи: X1, X2, X3, X4

Слой 2 - изчисления:

Стойности за тегла:

w(1,1), w(1,2), w(1,3), w(1,4) за скрит неврон (1,1)
w(2,1), w(2,2), w(2,3), w(2,4) за скрит неврон (1,2)

.....
w(6,1), w(6,2), w(6,3), w(6,4) за скрит неврон (1,6)

Отклонения:

b(1,1) за скрит неврон (1,1)
b(1,2) за скрит неврон (1,2)
.....
b(1,6) за скрит неврон (1,6)

Формули в Excel:

Скрит Неврон (1,1) = 1/(1+(EXP(-(X1*w(1,1) + X2*w(1,2) + X3*w(1,3)+X4*w(1,4)+b(1,1))

Скрит Неврон (1,2) = 1/(1+(EXP(-(X1*w(2,1) + X2*w(2,2) + X3*w(2,3)+X4*w(2,4)+b(1,2))

.....
Скрит Неврон (1,6) = 1/(1+(EXP(-(X1*w(6,1) + X2*w(6,2) + X3*w(6,3)+X4*w(6,4)+b(1,6))

Слой 3: Изчисления за

Стойности на тегла:

w(22,1), w(22,2), .. , w(22,6)

Отместване: b(2,1)

Формули в Excel:

Изходен неврон = 1/(1+(EXP(-(h(1,1)*w(22,1) + h(1,2)*w(22,2)+h(1,3)*w(22,3)+ .. + h(1,6)*w(22,6)+b(2,1))

Калкулиране грешка^2, MSE

Формули в Excel:

Error^2 = (X5 – ИЗХ())^2

MSE= Average(Error^2)

Run Solver add-in

Целева клетка: MSE (W24)

Регулируеми клетки: всички данни за тегло и отклонение (Об:O23;Q6:Q24);

Критерии: Минимизиране MSE

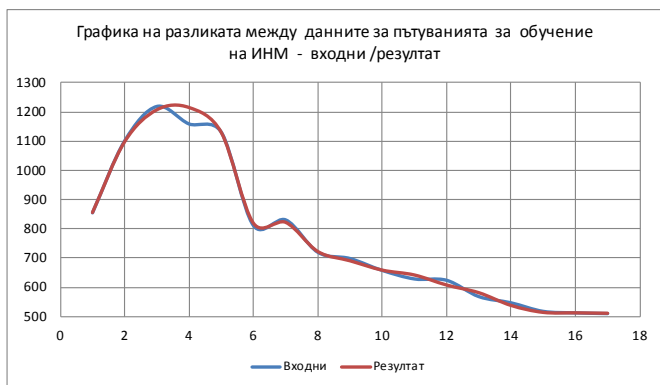
Показване на прогнозна диаграма и желан изход.

На фиг.5 е показана графиката на разликата между входните пътувания за обучение на ИНМ и съответните им получени в следствие на обучението резултатни пътувания.

	A	B	C	D	E	F	G	H	I	J	K	L
1	max	8283200	5200	9591	1336,48	1218,45		1	1	1	1	1
2	min	7144543	2800	1534	280,52	509,637		0	0	0	0	0
3		базови данни					интерполирани данни					
4		вход				изход	вход				изход	
5		X1	X2	X3	X4	X5	X1	X2	X3	X4	X5	
6		8283200	2900	1534	280,52	854,391	1,000	0,042	0,000	0,000	0,486	
7		8230400	3000	2199	317,91	1100,652	0,954	0,083	0,083	0,035	0,834	
8		8190900	2800	2412	321,95	1218,45	0,919	0,000	0,109	0,039	1,000	
9		8149468	3000	2685	319,52	1158,551	0,883	0,083	0,143	0,037	0,915	
10		7932984	3200	2908	320,53	1130,505	0,692	0,167	0,171	0,038	0,876	
11		7845841	3400	3099	326,45	810,872	0,616	0,250	0,194	0,043	0,425	
12		7801273	3600	3229	366,29	830,272	0,577	0,333	0,210	0,081	0,452	
13		7761049	3900	3491	540,21	719,382	0,541	0,458	0,243	0,246	0,296	
14		7720000	4100	3824	738,04	698,014	0,505	0,542	0,284	0,433	0,266	
15		7679290	4400	4187	846,52	657,362	0,470	0,667	0,329	0,536	0,208	
16		7640238	4700	5050	1091,24	628,161	0,435	0,792	0,436	0,768	0,161	
17		7606551	5000	6460	1336,48	623,544	0,406	0,917	0,611	1,000	0,161	
18		7563710	4800	7227	1072,22	567,808	0,368	0,833	0,707	0,750	0,082	
19		7504868	4900	7745	963,86	546,535	0,316	0,875	0,771	0,647	0,052	
20		7327224	5100	8362	905,39	517,254	0,160	0,958	0,847	0,592	0,011	
21		7284552	5200	8831	881,38	512,132	0,123	1,000	0,906	0,569	0,004	
22		7144543	5200	9591	865,68	509,637	0,000	1,000	1,000	0,554	0,000	

	A	N	O	P	Q	R	W	X	Y	Z	AA	AB
1	max			20		20						1218,45
2	min			-20		-20						509,64
3		слой 1				слой 2						
4									из. инт	егор*2		изход
5						h(1,1)...	h(1,6)					
6		w(1,1)	0,090	w(5,3)	-20,000	6,82E-05	0,439339	0,488	2,6E-06	855,53		
7		w(1,2)	-0,043	w(5,4)	-0,050	7,34E-05	0,444854	0,830	1,5E-05	1097,90		
8		w(1,3)	0,970	w(6,1)	-0,151	7,54E-05	0,444717	0,984	0,00026	1207,11		
9		w(1,4)	0,005	w(6,2)	0,109	7,74E-05	0,449326	0,995	0,00629	1214,75		
10		w(2,1)	-0,358	w(6,3)	-0,121	7,78E-05	0,459536	0,875	1,5E-06	1129,65		
11		w(2,2)	0,372	w(6,4)	0,023	7,88E-05	0,465415	0,436	0,00012	818,72		
12		w(2,3)	0,621	b(1,1)	-9,681	7,95E-05	0,469849	0,440	0,00014	821,85		
13		w(2,4)	1,222	b(1,2)	0,124	8,14E-05	0,476489	0,300	1,3E-05	721,96		
14		w(3,1)	-8,304	b(1,3)	6,032	8,43E-05	0,482426	0,255	0,00012	690,35		
15		w(3,2)	-3,161	b(1,4)	0,002	8,73E-05	0,489126	0,210	2E-06	658,36		
16		w(3,3)	7,293	b(1,5)	-8,056	9,62E-05	0,498386	0,186	0,00036	641,70		
17		w(3,4)	-1,503	b(1,6)	-0,097	0,000113	0,509531	0,138	0,00052	607,37		
18		w(4,1)	4,674	b(2,1)	-20,000	0,000124	0,510151	0,101	0,00035	581,13		
19		w(4,2)	0,194	w(22,1)	12,954	0,000131	0,514605	0,039	0,00016	537,62		
20		w(4,3)	-2,932	w(22,2)	-16,084	0,000139	0,524762	0,006	2,3E-05	513,82		
21		w(4,4)	0,000	w(22,3)	20,000	0,000146	0,528938	0,004	1,1E-08	512,21		
22		w(5,1)	20,000	w(22,4)	11,424	0,000158	0,536326	0,002	2,7E-06	510,79		
23		w(5,2)	-20,000	w(22,5)	14,097							
24				w(22,6)	0,106	MSE	0,000493					

фиг.4: екран на Excel за ИНМ за табл.1



фиг.5: Графика на разликата между данните за пътуванията за обучение на ИНМ - входни /резултат

5. Заключение

Разгледаното приложение на ИНМ в процеса на транспортно планиране дава резултати с много ниска грешка между получения от обучението и желаните резултати.

Модела ИНМ има както предимства, така и недостатъци. Основното предимство на ИНМ е възможност за разкриване на неочевидни връзки между зависими и независими променливи. От друга страна, съществува риск от използването му като "черна кутия". Могат да бъдат посочени два основни недостатъка. Първо, не е възможно да се формулират уравнения, подобни на регресионните уравнения. Обикновено при прогнозиране чрез невронна мрежа се използва същия софтуер, който се използва за разработване на модела. На второ място, ИНМ се нуждае от голям размер на извадката, което много често е трудно да се получи в транспортния анализ.

Освен за прогнозиране, невронните мрежи намират и друго основно приложение в транспортните процеси, свързано с моделиране на безопасността на движението.

ЛИТЕРАТУРА:

[1] Варадинова, Ю., *Модели за устойчиво развитие на железопътната инфраструктура*, София, ДТ-ВТУ, 2014.
 [2] Карагъзов К., В. Рангелов, *Прогнозиране и сегментиране на пазара на пътническите превози*, сборник доклади „Транспорт-2004“, ВТУ, София, 2004, стр. 59-64.
 [3] Размов Т., Л. Клямбарски, *Моделиране на търсенето на транспортни услуги за превоз на пътници с обществен транспорт в Република България*, МТК том 12, брой 3/1, 2014, стр. 38-46.
 [4] Arryex, *Create Neural Network in Excel*, Arryex, 2012, <www.trade2win.com/.../metatrader/136002d1336321092-build-neural-network-indicator-mt4-using-neuroshell-create-neural-network-excel.pdf>
 [5] Goel S., A. K. Sinha, *Trip Generation Modeling Using Artificial Neural Network*, Proceedings of the 2nd National Conference; INDIACOM – 2008, New Delhi
 [6] Tillema F., K.M. van Zuilekom, M.F.A.M van Maarseveen, G. Huisken, *Trip generation and trip distribution: Comparison of neural networks and traditional methods*, . In: 10th World Conference on Transportation Research, WCTR 2004, 4-8 July 2004, Istanbul, Turkey, < <http://doc.utwente.nl/81915/1/Tillema04trip.pdf>>.
 [7] Национален статистически институт, < <http://www.nsi.bg/>>