



Получена: 01.04.2022 г.

Приета: 19.04.2022 г.

## ОПРЕДЕЛЯНЕ НА ЛИНЕЙНА ТОПЛОПРОВОДИМОСТ НА ТОПЛИННИ МОСТОВЕ В СЕИЗМИЧНИ РАЙОНИ ЧРЕЗ ИЗКУСТВЕНА НЕВРОННА МРЕЖА

Ст. Иванова<sup>1</sup>

*Ключови думи:* MS Excel, VBA, регресионен анализ, топлинни загуби, обучение, HTML, JavaScript

### РЕЗЮМЕ

Загубите от топлопреминаване през топлинните мостове представляват значима част от общите топлинни загуби на сградите. Затова определянето на коефициента на линейна топлопроводимост  $\psi$  на топлинните мостове е от голяма важност. Поради многообразието на сградни конструкции и решения, които водят до различни комбинации от геометрични и физически параметри на топлинните мостове, за тази цел се използват скъпи специализирани софтуери за моделиране на топлинните потоци през сградните конструкции. Друго възможно решение са каталозите на топлинни мостове, които съдържат комплекти от геометрични данни и съответните им стойности на  $\psi$ . В тази връзка настоящата разработка представя иновативна методика за бързо, ефективно и прецизно определяне на коефициента  $\psi$  на линеен топлинен мост, като се използва регресионен анализ и обучена за целта изкуствена невронна мрежа.

### 1. Въведение

Постигането на енергийно ефективни сградни решения е възможно чрез баланс на топлинни печалби и значително намалени топлинни загуби, които през зимния период включват:

---

<sup>1</sup> Стоянка Иванова, доц. д-р арх., кат. „Автоматизация на инженерния труд”, УАСГ, бул. „Хр. Смирненски“ № 1, 1046 София, e-mail: siva\_fce@uacg.bg

- загуби от топлопреминаване през сградната обвивка (през околни стени, покрив, остъклени части, топлинни мостове и др.);
- загуби от вентилация вследствие на смяната на въздуха в сградата с външен въздух;
- загуби от излъчване на топлина към небосвода и други повърхности с по-ниски температури.

Топлинните загуби  $H_T$  от топлопреминаване през сградната обвивка се определят с помощта на форм. (1):

$$H_T = \sum_i A_i U_i + \sum_k l_k \psi_k + \sum_j \chi_j, \quad (1)$$

където  $A_i$  е площ на равнинен сграден елемент  $i$ ,  $m^2$ ;

$U_i$  – коефициент за топлопреминаване на елемент  $i$ ,  $W/(m^2K)$ ;

$l_k$  – дължина на линеен топлинен мост  $k$ ,  $m$ ;

$\psi_k$  – коефициент на топлопроводимост на линеен топлинен мост  $k$ ,  $W/(mK)$ ;

$\chi_j$  – коефициент на топлопроводимост на точков топлинен мост  $j$ ,  $W/K$ .

Сред посочените във форм. (1) топлинни загуби, тези през топлинните мостове имат значимо място, понеже по консервативни оценки за страни в сеизмични райони са доста над 20 – 25% от общите топлинни загуби от топлопреминаване през стените [1], въпреки че площта им върху фасадите е много по-малка.

Топлинните мостове представляват места в сградната обвивка, които превеждат топлина отвътре навън и обратно, по-интензивно от другите ѝ части. Точно определение е дадено в [2, чл. 3.1.1] и според него, топлинен мост е част от обвивката на сградата, където съпротивлението на топлопреминаване се променя значително по една или няколко от следните възможни причини:

- пълно или частично проникване в сградната обвивка на материали с различна топлопроводимост;
- промяна в дебелината на основния елемент;
- изменение на конфигурацията на елемента (при външни и вътрешни ъгли, връзка стена–покрив, връзка стена–под, връзка стена–вътрешна стена и др.).

Топлинните мостове са многообразни – биват линейни, точкови, геометрични, конструктивни, смесени (геометрично-конструктивни), конвективни и др. От тях по-значими са геометрично-конструктивните, които в състава си включват сградни елементи с висока плътност и топлопроводимост – например плочи, греди и колони от стоманобетон или метал, които са в непосредствена близост с външното пространство.

Редуцирането на неблагоприятния ефект на топлинните мостове чрез поставяне на топлоизолация върху тях има ключово значение за намаляване на общите топлинни загуби, за по-лесно постигане на енергиен баланс и за значително снижаване на нуждата от отопление през зимата и охлаждане през лятото, което пък в крайна сметка води до намалени въглеродни емисии при експлоатиране на сградите.

Въпреки модулността, използвана в строителството, многообразието на сградни конструкции и решения води до различни комбинации от геометрични и физически параметри на топлинните мостове. За оценка на влиянието на вече споменатите линейни топлинни мостове се определя коефициентът на линейна топлопроводимост (*linear*

*thermal transmittance*)  $\psi$  на топлинния мост, измерван в  $W/(mK)$ , като от значение  $\epsilon$  и коефициентът за топлопреминаване  $U$  на прилежащата стена, измерван в  $W/(m^2K)$ .

По дефиниция коефициентът на линейна топлопроводимост  $\psi$  (*Psi value*) се изчислява като разлика от топлинния поток през целия елемент и топлинния поток през съставните му части – форм. (2):

$$\psi = \frac{Q'_{\text{общо}} - Q'_{\text{поотделно}}}{\Delta\theta}, \quad (2)$$

където  $Q'_{\text{общо}}$  е общ топлинен поток (загуби на линеен метър) през съвкупността от елементите, определящи топлинния мост,  $W/m$ ;

$Q'_{\text{поотделно}}$  – сума на линейни топлинни потоци (загуби на линеен метър) поотделно през елементите,  $W/m$ ;

$\Delta\theta$  – температурна разлика между вътрешната и външната страна на конструкцията,  $^{\circ}C$ .

Съгласно EN ISO 10211-2 коефициентът на линейна топлопроводимост  $\psi$  се изчислява с форм. (3), която следва от форм. (2):

$$\psi = \frac{Q'_{\text{общо}}}{\Delta\theta} - (U_1L_1 + U_2L_2), \quad (3)$$

където  $U_1$  и  $U_2$  са коефициентите за топлопреминаване на зоните от двете страни на линейния топлинен мост, а  $L_1$  и  $L_2$  са дължините на зоните в перпендикулярна посока на моста. Стойност на  $\psi < 0,01 W/(mK)$  се приема за пренебрежимо малка и означава, че съответният линеен топлинен мост практически не оказва влияние върху топлинните загуби на сградата. Сграда със стойност на топлинните загуби през линейни и точкови топлинни мостове, по-малка или равна на 0, се счита за сграда без топлинни мостове (*thermal bridge free design*) [3].

Изчисляването на коефициента за топлопреминаване  $U$  при линейно хомогенни сградни елементи става сравнително лесно с форм. (4) по DIN EN ISO 6946:

$$U = R_T^{-1} = \left( R_{si} + \sum \frac{d_i}{\lambda_i} + R_{se} \right)^{-1}, \quad (4)$$

където  $R_T$  е сумарно топлинно съпротивление,  $m^2K/W$ ;

$d_i$  – дебелина на  $i$ -ти пласт на сградната конструкция,  $m$ ;

$\lambda_i$  – коефициент на топлопроводност на  $i$ -ти пласт на сградната конструкция,  $W/(mK)$ ;

$R_{si}$  – вътрешно съпротивление на топлопредаване, със стойности от 0,10 до 0,17, типичната му стойност 0,13  $m^2K/W$  е известна още като *inside standard* [4];

$R_{se}$  – външно съпротивление на топлопредаване, със стойност 0,04  $m^2K/W$ , която е известна още като *outside standard* [4].

За разлика от  $U$ , стойността на коефициента на линейна топлопроводимост  $\psi$  се определя сравнително по-трудно. За целта е нужен специализиран софтуер, който пресмята топлинния баланс на елемента, обикновено (но не само) по метода на крайните елементи (чрез разделяне на площта на сечението на конструкцията на огромен брой триъгълници). Примери за такъв софтуер са *BISCO* на белгийската фирма *Physibel* [5] за

линейни топлинни мостове, който е верифициран със стандарта МКС EN ISO 10211 [6], както и *COMSOL* (Comsol 2006) [7, 8], *TRISCO* (също на фирмата Physibel) [9], *FLIXO* [10] и др. Трябва да се спомене и българската програма за температурни полета *TEPOL*, описана подробно в [11], чието приложение е демонстрирано в [12, 13]. Тези сравнително универсални, и обичайно доста скъпи програмни продукти не са подходящи за ежедневна работа на проектантите, затова най-често с тяхна помощ се изготвят каталози на топлинни мостове за приложение в проектирането. Каталогите могат да бъдат с опростени решения, например [14]. Пример за доста по-разгърнат и подробен каталог е този на линейни топлинни мостове в сгради в сеизмични райони на д-р инж. арх. Петар Николовски [15, 16]. В каталога размерите на сградните елементи се променят през определена стъпка (за конструктивни елементи – през 5 или 10 cm, за топлоизолация – през 2 cm) и се използват типични стойности на коефициента на топлопроводност, например  $\lambda = 0,04 \text{ W/(mK)}$  за топлоизолация,  $\lambda = 0,45 \text{ W/(mK)}$  за тухлен зид и  $\lambda = 2,50 \text{ W/(mK)}$  за стоманобетонни елементи – греди и плочи. Каталогът на Николовски включва над 350 типични за строителната практика на Балканите линейни топлинни мостове, структурирани в групи и подгрупи. Той е приложим и в България, защото решава задачи в специфичните условия на сеизмични райони, в какъвто попада и нашата страна. Въпреки че каталогът се опитва да включи всички съществени варианти, все пак е възможно в практиката да се наложи определяне на коефициента  $\psi$  на топлинен мост, чиито размери не съвпадат точно с размерите, дадени в каталога. Възможно е желаните междинни стойности на  $U$  и  $\psi$  да могат да се получат с интерполация, но това изисква допълнителни усилия и време и увеличава елемента на несигурност поради възможността за внасяне на човешка грешка.

По тази причина представлява интерес възможността да се провери дали може да се използва т.нар. регресионен анализ с помощта на изкуствена невронна мрежа (*artificial neural network*, ANN) за определяне на коефициента на линейна топлопроводимост  $\psi$  на топлинните мостове.

Целта на тази разработка е да провери тази възможност. Прегледът на световните литературни данни на английски език не показва други предишни реализации на тази идея, което най-вероятно означава, че тя е оригинален принос на авторката на настоящата публикация.

## 2. Метод на регресионен анализ с изкуствени невронни мрежи

Регресионният анализ [17] е направление в математическата статистика, в което се изучават и оценяват възможните функционални зависимости между две или повече случайни величини. Целта му е да се определи дали съществува взаимна зависимост между тези величини и да се намери функцията, която да я описва достатъчно точно.

Трябва да се отбележи, че същността на моделирания процес и конкретният смисъл на данните не са от значение при регресионния анализ, както и причините за връзката между величините. От значение е само да се установи как една величина  $Y$  зависи от стойностите на няколко други –  $x_1, x_2, \dots, x_n$  – форм. (5), като е важно да бъде покрита цялата дефиниционна област на входните данни и на търсената величина.

$$Y = f(x_1, x_2, \dots, x_n). \quad (5)$$


Невронните мрежи са много успешно средство за реализация на метода на регресионен анализ. Те не използват формули, както при обичайното програмиране, а се обучават чрез примери, натрупани с наблюдения или експерименти (в т.ч. числови). В [18,

19] са разгледани многобройни примери за използване на невронни мрежи за архитектурни и строителни приложения, а в [20] – за различни инженерни приложения.

Може да се очаква, че съдържанието на каталозите за линейни топлинни мостове би могло да представлява средство за обучение на невронни мрежи. В идеалния случай всеки каталог би следвало да може да се преобразува в множество обучени невронни мрежи, чиито тегловни коефициенти са записани във вид на правоъгълни таблици (матрици). В зависимост от близостта на топлинните мостове в отделните дялове на каталога може би ще е възможно някои негови части да се обединят в общи невронни мрежи. При този подход обучените ANN ще споделят спецификите на каталога, който е използван – например ограничение на използваните материали и оттам – фиксирани стойности на коефициента на топлопроводност  $\lambda$  за тях.

## 2.1. Въведение в обучението на изкуствените невронни мрежи

Концепцията за изкуствени невронни мрежи [21] реализира в себе си компютърен аналог на специфично свързани в система неврони, за които важат следните твърдения: 1) невроните са разделени на пластове с различно предназначение – входен (*input layer*), скрит(и) (*hidden layer*), изходен (*output layer*) (фиг. 1); 2) всеки неврон е свързан с всички неврони от предходния и следващия пласт с връзка, която е способна да се настройва; 3) всеки неврон преработва по специален начин (чрез активационна функция) влиянието на всички неврони от предния пласт и подава резултата от тази обработка на всички неврони от следващия пласт.



**Фиг. 1. Примерна архитектура на невронна мрежа с един скрит пласт, изчертана с [23]. В случая параметрите ѝ отговарят точно на използваната в тази разработка мрежа**

Съвкупността от неврони във вид на организирана мрежа използва входни данни и генерира краен резултат и е способна на обучение за по-качествено изпълнение на тази задача. С помощта на *Universal Approximation Theorem* [22] е доказано математически,

че ANN с повече от един скрит слой с достатъчен брой неврони може да моделира поведението на всяка съществуваща функция.

Връзките между невроните от различните пластове се моделират с числени тегловни коефициенти (*weights*), които усилват или отслабват значението на съответните зависимости между тях. Обучението на изкуствена невронна мрежа по същество представлява настройване на коефициентите ѝ, които да водят към търсената закономерност между входни и изходни данни. Например при невронна мрежа с един входен пласт с 5 входни данни и скрит пласт с 10 неврона и един изходен пласт с един резултат се настройват  $10 \times (5 + 1) + (10 + 1) = 71$  коефициента (фиг. 1). Една част от тях (в случая 10 + 1) служат за настройване на отклонението от желаната стойност (*bias*).

Много популярен при регресионния анализ с ANN е методът на обратно разпространение на грешката (*back propagation error*) [20]. При него основната идея е многократното изчисляване на разликата между желана и получена стойност и промяна на коефициентите с цел намаляване на тази грешка. Еднократното обучение с комплекта данни се нарича *epoch*. Обичайно една ANN се обучава с хиляди (до милиони) повторения (епохи).

Най-често определянето на броя скрити пластове и техните неврони става експериментално. Правилото е, че по-сложните зависимости се програмират с повече неврони, и евентуално и пластове.

Технологията за обучение на ANN чрез обратно разпространение на грешката е, както следва: първо трябва да бъдат определени променливите, които участват като входни параметри. Желателно е техният брой да не е много голям. Ако сред тях има такива, които не влияят на търсените резултати, след обучението на тях ще съответстват нулеви или почти нулеви стойности на тегловните коефициенти, т.е. по време на обучението си невронната мрежа сама разграничава влияещите от невлияещите входни параметри [20]. Състоянието (стойността) на всеки неврон  $v$  в първия скрит слой се определя като сума на произведенията на всеки вход  $x_j$  със съответния тегловен коефициент  $w_j$  и отклонението  $b$  (*bias*) – вж. форм. (6).

$$v = \sum_{j=1}^m w_j x_j + b. \quad (6)$$

Освен от тегловните си коефициенти, невронните мрежи се определят и от активационните функции (*activation functions*) на всеки свой слой, без входния [22]. Тези функции могат да бъдат съвсем прости или по-сложни, например: линейна (*linear*) – форм. (7.1); логсигмоидална (*sigmoid*) – форм. (7.2); тангенс хиперболична – форм. (7.3); ReLu – форм. (7.4) и др.

$$f(x) = cx; \quad (7.1)$$

$$f(x) = 1 / (1 + e^{-x}); \quad (7.2)$$

$$f(x) = 2 / (1 + e^{-2x}) - 1 = 2 \text{sigmoid}(2x) - 1; \quad (7.3)$$

$$f(x) = \max(0, x). \quad (7.4)$$

Особеност на невронните мрежи е, че те са по-ефективни при нормализирани входни и изходни данни (със стойности между 0 и 1). Нормализацията се реализира чрез форм. (8).

$$A = (V - V_{\min}) / (V_{\max} - V_{\min}), \quad (8)$$

където  $V_{\min}$  и  $V_{\max}$  са възможните минимална и максимална стойност на променливата  $V$ , а  $A$  е нейната нормализирана стойност. Често използваната лог-сигмоидална активационна функция води до стойности на изхода от всеки неврон в обхвата от 0 до 1, затова накрая се налага денормализация на крайния резултат, с форм. (9).

$$V = V_{\min} + A(V_{\max} - V_{\min}). \quad (9)$$

Обичайно подготвените за обучението големи бази данни, които съдържат входни данни и резултати, се разделят на две групи: 1) за обучение на ANN, и 2) за тестване на обучената ANN, в съотношение 2 към 1. Обучението започва със случайни начални стойности на тегловните коефициенти на невроните. След това ANN се запазва с подготвените за обучение данни и с помощта на обратно разпространение на грешката постепенно и в многобройни епохи настройва своите коефициенти. Обучението продължава определен брой епохи или докато средната квадратична грешка (RMSE) в една епоха падне под определена, предварително зададена стойност. Накрая ANN се тества с данните, специално определени за това. Средната квадратична грешка RMSE (Root Mean Square Error) се изчислява за всяка епоха с форм. (10), където  $Y_T$  е желаната стойност, а  $Y_C$  е изчислената с ANN стойност. Целта е тази грешка постоянно да намалява по време на обучение, докато достигне минимум.

$$RMSE = \sqrt{\frac{\sum (Y_T - Y_C)^2}{\sum Y_T}}. \quad (10)$$

### 3. Обучение на изкуствена невронна мрежа за определяне на линейната топлопроводимост на топлинни мостове


#### 3.1. Подготовка на данни за обучение на ANN

За проверка на предположението, че параметрите на топлинните мостове могат успешно да се моделират с изкуствени невронни мрежи, бяха използвани данните в подгрупи IF1 (IF1-1 до IF1-6) и IF3 (IF3-1 до IF3-5) в каталога на линейните топлинни мостове на Петар Николовски [15]. Те представляват модели на подови линейни топлинни мостове като връзки на зидана фасадна стена и стоманобетонна междуетажна плоча с дебелина 16 cm и греда, с топлоизолация отвън (случаи IF1-1 до IF1-6) и отвътре (случаи IF3-1 до IF3-5). В първата група има 42 комбинации с размери на гредата от  $30 \times 20$  до  $50 \times 50$  cm, с топлоизолация от 8 до 20 cm, разположена външно, а във втората – 35 подобни комбинации, но с вътрешна топлоизолация с дебелина пак от 8 до 20 cm. Избрани стойности от каталога за подгрупи IF1 и IF3 са записани в 11 таблици и от тях могат да се изготвят 77 комплекта данни за обучение, които включват следните стойности (вж. фиг. 2):

- $a$  – височина на гредата, cm;
- $b$  – ширина на гредата, cm;
- $c$  – дебелина на зида, cm;
- $d_{ext}$  – дебелина на външната топлоизолация, cm;
- $d_{int}$  – дебелина на вътрешната топлоизолация, cm;

$\psi_e$  – външен коефициент на линейна топлопроводимост на топлинния мост,  $W/(mK)$ , изчислен на база външни размери.

По принцип обучението трябва да разполага с достатъчно голяма и представителна база данни. Препоръчва се за обучението да има от 5 до 10 записа за всеки тегловен коефициент [21]. Тъй като невронните мрежи се обучават на линейни взаимовръзки по-ефективно, една от целите при изготвянето на данните е да се намали нелинейността. Ако дадена данна  $X$  е реципрочна на резултата, по-ефективно е вместо нея да се използва  $(1/X)$  [20].



**Фиг. 2.** Схема на линейен топлинен мост, включващ стоманобетонна гредка и плоча, зидана стена и външна и вътрешна топлоизолация. Схемата обединява случаи IF1 и IF3 от [15]

Принципно е възможно стойността на коефициента за топлопреминаване  $U$  да се изчисли с обучена невронна мрежа, но с оглед на това, че той се изчислява лесно с формула (4), не е нужно да се моделира по по-сложен начин.

### 3.2. Настройване на ANN за задачата с топлинните мостове

В настоящата задача входните параметри са пет и са изцяло геометрични: 1) височина на гредата, 2) ширина на гредата, 3) дебелина на зиданата стена, 4) дебелина на външната топлоизолация, и 5) дебелина на вътрешната топлоизолация. На тях се съпоставя резултат за линейния коефициент  $\psi_e$  на топлинния мост, т.е. всеки запис (ред) в базата данни за обучение и тестване трябва да включва тези 6 стойности. Обикновено преди да се предадат за обучение, данните преминават предварителна (препроцесорна) обработка, която включва следните четири стъпки:

1. Конвертиране на данните във формата, изискван за обучение на ANN в записи, които включват редове с необходимите входни данни и съпоставен на тях резултат.
2. Разделяне на общата база данни на две групи: а) за обучение на ANN; б) за тестване на ANN, в съотношение 2 към 1 [20].
3. Нормализиране на входните данни и желаните резултати преди подаването им към ANN.



- Разбъркване на редовете в БД по случаен начин, което увеличава ефективността на обучението.

В резултат на стъпка 1 по настоящата задача се генерира малка база данни (БД) с общо 77 реда (записа) с числови данни за съответствието между комбинацията от геометрични параметри на топлинния мост от една страна и съответната стойност на  $\psi_e$ , от друга страна. Базата данни е с размер около 3,7 KB и е записана във файл *Thermal-Bridges-IF1&IF3-Input data.txt* (вж. в архива [24]).

В изпълнение на стъпка 2 бяха създадени две части на БД, едната с 49 записа – за трениране, и още една по-малка с 28 записа – за тестване. Първата включва записи със стойности на  $d_{ext}$  и  $d_{int}$ , равни на 8, 12, 16 и 20 cm, а втората – с  $d_{ext}$  и  $d_{int}$ , равни на 10, 14 и 18 cm.

Нормализирането на данните се изпълнява с помощта на форм. (8), като се използват предварително зададени минимална и максимална стойност на обхвата на всеки параметър, както следва:

$a$  – от 30 до 60 cm (височина на гредата);

$b$  – от 20 до 50 cm (ширина на гредата);

$c$  – от 20 до 25 cm (дебелина на зида);

$d_{ext}$  – от 0 до 20 cm (дебелина на външната топлоизолация);

$d_{int}$  – от 0 до 20 cm (дебелина на вътрешната топлоизолация);

$\psi_e$  – от 0 до 2 W/(mK) (външен коефициент на линейна топлопроводимост на топлинния мост).

### 3.3. Обучение на изкуствената невронна мрежа

Съществуват различни софтуерни продукти за работа с ANN. Един от най-популярните е *Neural Network Toolbox* на *MatLab* [25]. Той притежава графичен интерфейс, поддържа 6 типа невронни мрежи, дава възможност за създаване на собствени трансферни функции и е програмируем в средата на *MatLab*.

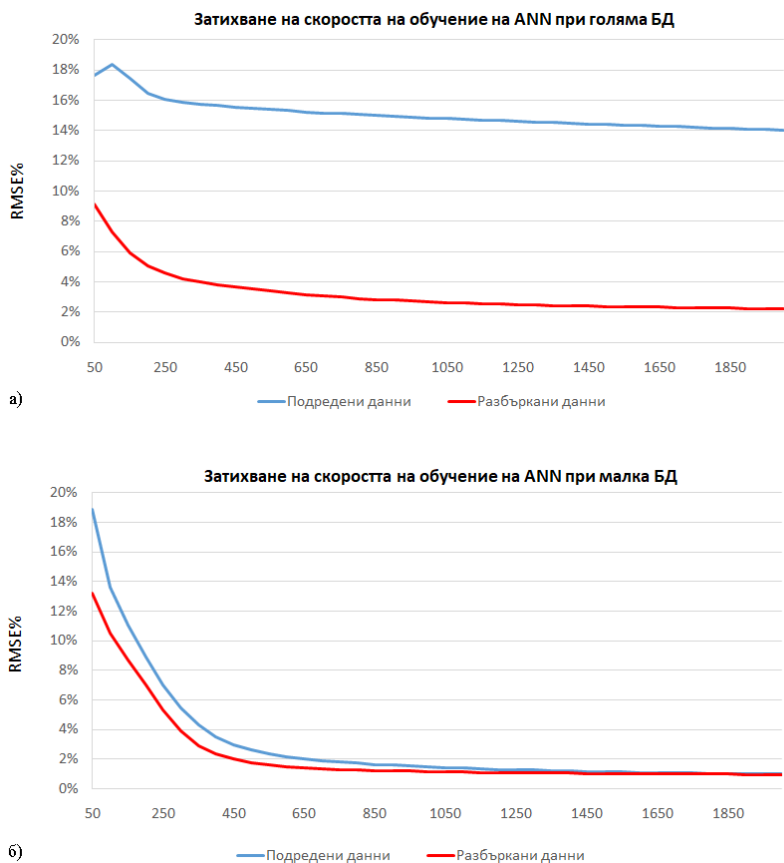
	А	В	С
1	Данни за обучение	Thermal-Bridges-IF1&IF3-Input data-for training.txt	Трениране на ANN
2	Данни за тестване	Thermal-Bridges-IF1&IF3-Input data-for testing.txt	
3	Тегловни коефициенти	Thermal-Bridges-IF1&IF3-Weights.txt	Тестване на ANN
4	Входни данни	5	Изчертай фигура за сравнение
5	Скрити неврони	10	
6	Скорост на обучение	0.8	
7	enhance	0.01	Запис на JavaScript код
8	Активационна ф-я 1	1	
9	Активационна ф-я 2	1	
10	Брой епохи	1000000	
11	Общ брой епохи	1000000	
12	Разбъркване	No	
13	Начало	15:39:24	
14	Край	15:45:23	
15	Време за трениране	0:05:59	
16	RMSE при трениране	0.071%	
17	RMSE при тестване	0.096%	

Фиг. 3. Съдържание на таблицата с параметри за обучение на ANN във файла *Thermal-Bridges-IF1&IF3-Training.xml*. Време за трениране на 1 000 000 епохи – 6 минути за процесор Intel(R) CPU @ 2,90 GHz

В настоящата задача обаче е използван софтуер за обучение на ANN с обратно разпространение на грешката и 4 различни типа активационни функции, разработен от авторката на настоящата публикация в средата на MS Excel и с програмния език VBA (фиг. 3), който работи с 3 пласта на невронната мрежа:

- входен пласт (*Input layer*) с толкова неврони, колкото и входни параметри има в задачата;
- скрит пласт (*Hidden layer*) с променлив брой неврони;
- изходен пласт (*Output layer*) само с един неврон за един резултат.

По отношение на търсенето на минимална квадратична грешка RMSE обучението на ANN не е линейно, а затихващ процес, т.е. в началото грешката бързо намалява, а после това става все по-бавно, като може да достигне и локален минимум (различен от абсолютния минимум) (фиг. 4). В такива случаи се прилагат техники за излизане от него и търсене на друг по-нисък минимум. Тези техники включват промени на скоростта на обучение чрез променливите *Learning\_rate* (Скорост на обучение) и *enhance*, ново разбъркване на данните или обучение само с част от данните и др.



**Фиг. 4. Затихване на скоростта на обучение и съответно на намаляването на грешката в процеса на обучение при 2000 епохи: а) невронна мрежа с голяма БД (15367 записа); б) невронна мрежа с малка БД (77 записа)**

Причината, по която е избран MS Excel като среда, и VBA – като програмен език за моделиране на ANN е с цел демонстрация на достъпността и лекотата, с която може да се създаде и обучи една изкуствена невронна мрежа по метода на обратно разпространение на грешката. Идеята е да се популяризира и поощри използването на невронни мрежи за решаване на архитектурно-строителни и инженерни задачи.

#### 4. Резултати от обучението, тестване и използване на обучена ANN

Вече беше споменато, че след обучението една невронна мрежа се проверява с тестов комплект данни, като трябва да даде грешка, близка до тази в края на обучението. В настоящия случай базата данни за обучение е много малка, затова стъпка 2 (за разделянето ѝ на две части) е дискуссионна. С цел да се прецени дали това действие е ефективно, бяха направени тестове със и без него. Резултатите са илюстрирани в табл. 1. Пак там са показани и резултатите от обучението без и със случайно разбъркване на данните (фиг. 4б). Тестването на различните изчислителни варианти става при едни и същи случайни начални стойности на тегловните коефициенти на ANN, за да има съпоставимост на резултатите.

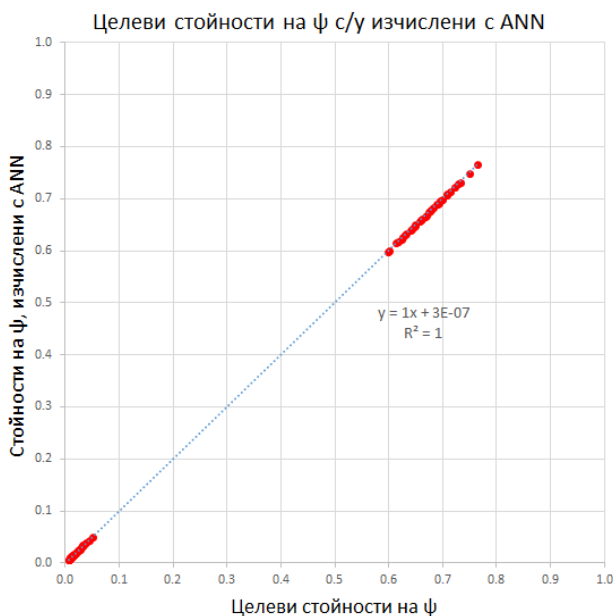
**Таблица 1. Резултати от тестване на невронната мрежа със и без разбъркване на записите, с обща и с разделена база данни, при  $Learning\_rate = 0,8$**

№	Режим на разбъркване	RMSE при трениране	RMSE при тестване	Брой записи в базата данни	Време
1	Без разбъркване, 1 000 000 епохи	0,071%	0,096%	за трениране – 49 за тестване – 28	6 min
2	Със случайно разбъркване, 1 000 000 епохи	0,078%	0,099%	за трениране – 49 за тестване – 28	6 min
3	Без разбъркване, 1 000 000 епохи	0,072%	0,067%	за трениране – 77 за тестване – 28	9,5 min
4	Със случайно разбъркване, 1 000 000 епохи	0,077%	0,070%	за трениране – 77 за тестване – 28	9,5 min
5	Без разбъркване, 631 579 епохи	0,076%	0,070%	за трениране – 77 за тестване – 28	6 min
6	Със случайно разбъркване, 631 579 епохи	0,078%	0,070%	за трениране – 77 за тестване – 28	6 min

Обичайно при големи бази данни за обучение разбъркването на записите (чрез размяна на случайни редове) е *ключово* за повишаване на ефективността на обучение, както е показано на фиг. 4а. Опитът за прилагане на това действие при малки бази данни с кратки серии показва, че това правило важи само при малък брой епохи на обучение – до около 1 500 (вж. фиг. 4б). При по-голям брой епохи (над 10000), които са нужни за постигане на много ниска грешка, невронната мрежа се обучава видимо по-ефективно без разбъркване на данните, което може да представлява интерес за по-нататъшно изследване с цел увеличаване на ефективността на обучение на ANN. Това се вижда в табл. 1. Също така от резултатите в таблицата става ясно, че когато малката БД се раздели на 2 части (случаи 1 и 2), липсата на достатъчно данни за обучение води до по-висока грешка (от 0,096% до 0,099%) при тестване на обучената мрежа. Съответно, ако се използва пълният брой записи за обучение (случаи 3 и 4), грешката при тестване на ANN е по-ниска (от 0,067% до 0,070%) при същия брой епохи за обучение (1 000 000). Ако броят епохи се намали обратнопропорционално на увеличавания брой записи за обучение (от 49

на 77) до 631 579 (случаи 5 и 6), за да се уеднакви изчислителното време на 6 минути, се получава  $RMSE = 0,070\%$  при тестване, без значение дали обучението е без или със разбъркване на данните.

Съществена характеристика на създадения модел с помощта на регресионен анализ с ANN е, че той е „непрекъснат“, а не съдържа само фиксирани стойности, както е в каталога. Това позволява чрез него да се обработват размери на елементите, различни от тези в каталога, стига да са в посочената дефиниционна област на размерите им.



**Фиг. 5.** Сравнение на стойностите на коефициента  $\psi_e$ , използвани за обучение (в хоризонтална посока) с моделираните с ANN такива (във вертикална посока)

На фиг. 5 са показани съответствията на тестовите стойности на коефициента  $\psi_e$  (в хоризонтална посока) и моделираните с невронни мрежи (във вертикална посока). Колкото по-близо до диагонала на фигурата са изобразените точки, толкова по-качествен е резултатът от обучението. Вижда се, че коефициентът на корелация  $R^2$  е 1, което говори за изключително добре обучена ANN. В графиката стойностите долу вляво отговарят на случаите с външна изолация, а тези горе вдясно – на случаите с вътрешна изолация, които имат много по-големи стойности на  $\psi_e$ . Тази графика показва и какви са граничните дефиниционни стойности на коефициентите  $\psi_e$  в конкретните разгледани случаи IF1 и IF3. Графиката е построена с данните, които се генерират с натискане на бутона *Изчертай фигура за сравнение* (вж. фиг. 3).

В настоящата задача обучението завършва с  $RMSE = 0,064\%$  при 10 000 0000 епохи с 10 неврона и  $0,064\%$  при тестване на мрежата. Възможно е това да е локален минимум, достигнат при максимално намаляване на скоростта на обучение до 0 (контролирана чрез променливата *Learning\_Rate*). Няма как да се разбере дали това е локален или абсолютен минимум, без да се правят нови опити да бъде достигната по-ниска грешка RMSE. При всяко положение грешка от порядъка на  $0,06\%$  е изключително ниска и напълно достатъчна за настоящата задача. Тя означава, че максималното отклонение на изчислените с ANN стойности на коефициента  $\psi_e$  се различават от целевите (в каталога) с

най-много до  $\pm 0,001$  W/(mK). Толкова ниска грешка подсказва, че може би невронната мрежа за тази задача може да бъде достатъчно добре обучена и с по-малко неврони при евентуално малко по-висока крайна грешка. Все пак с оглед на незначителния размер на комплекта параметри на ANN, който е крайният резултат от обучението ѝ и представлява малък файл с размер около 1 KB, допълнителното му намаляване не може да бъде пречено като носещо значима полза.

#### 4.1. Примери за използване на изкуствената невронна мрежа

В архива на настоящата публикация [24] са демонстрирани 3 различни начина за използване на коефициентите на една тренирана невронна мрежа.

##### 4.1.1. Използване на ANN в MS Excel

В архива [24] е включен файл *Thermal-Bridges-IF1&IF3-Training.xlsm*, в който използването на коефициентите на ANN е показано с формули в лист *Weights*, за да бъде по-лесно разбрано (вж. фиг. 6). В жълто са показани входните данни и техните минимални и максимални стойности. В оранжево е посочен целевият резултат за  $\psi_e$ , както и изчисленият с ANN. Параметрите на обучената невронна мрежа (тегловните коефициенти и отклоненията) са посочени в синьо. Изчисленията са показани с формули в зелено вдясно, както и формулата за денормализиране, а грешката е в червено.

	A	B	C	D	E	F	G	H	I	J	K	L
1		a	b	c	d_ext	d_int	Target Psi	Ето как работи невронната мрежа!				
2	Оригинални входни данни	30	20	20	10	0	0.019					
3	Минимум	30	20	20	0	0	0					
4	Максимум	60	50	25	20	20	2					
5	Нормализирани входни данни	0	0	0	0.5	0	0.0095					
6	Тегловни коефициенти & Отклонения							Изчисления				
		Тегло_a	Тегло_b	Тегло_c	Тегло_d_ext	Тегло_d_int	Тегло_out	Отклонение	Сума Т*входове	Активация	Акт*Тегло_out	
8	Неврон 1	0.7749	1.1993	0.3406	-0.1025	1.6277	1.2279	0.6446	0.5933	0.6441	0.7909	
9	Неврон 2	0.9415	0.5108	0.2980	0.8523	0.4528	-0.0134	0.1519	0.5781	0.6406	-0.0086	
10	Неврон 3	-0.3541	0.5029	0.0812	8.6904	2.3527	-5.5622	0.2530	4.5982	0.9900	-5.5067	
11	Неврон 4	0.5808	-0.3513	-0.3319	-0.5941	-0.3932	1.5482	-0.2689	-0.5660	0.3622	0.5607	
12	Неврон 5	1.9629	1.5344	0.8451	1.6846	0.3883	-1.2532	0.2067	1.0490	0.7406	-0.9281	
13	Неврон 6	0.4954	-0.5265	0.3000	-1.1518	0.8961	2.0597	0.5324	-0.0436	0.4891	1.0074	
14	Неврон 7	-0.0326	-0.1665	0.0814	3.7410	0.4139	-1.4651	0.7740	2.6446	0.9337	-1.3680	
15	Неврон 8	0.0899	-0.3631	-0.7238	2.0250	0.2963	-1.2127	0.0376	1.0501	0.7408	-0.8983	
16	Неврон 9	-0.3814	0.5879	0.0029	-2.6145	3.2359	2.7119	-0.3353	-1.6425	0.1621	0.4397	
17	Неврон 10	0.3839	0.0459	0.1659	-0.0390	-0.2696	0.7016	0.1259	0.1064	0.5266	0.3694	
18	Отклонение	0.8948							Сума+Отклонение:		-4.6467	
19									Нормализиран резултат:		0.0095	
20									Денормализиран краен резултат:		0.0190	
21												
22												Грешка: 0.02%

Фиг. 6. Таблица с параметри на тренирана ANN след 1 000 000 епохи и пример как се използват коефициентите ѝ за получаване на резултат във файл *Thermal-Bridges-IF1&IF3-Training.xlsm*. Целевият резултат в този пример е 0,019, резултатът от ANN съвпада, грешката (след третия знак след десетичната точка) е 0,02%

##### 4.1.2. Използване на ANN чрез VBA в MS Excel и други приложения в MS Office

Във файла *Thermal-Bridges-IF1&IF3-Using.xlsm*, който е част от архива на публикацията [24], е демонстрирано как може да се изчисли по-голяма серия от коефициенти  $\psi_e$  по зададени в таблица входни данни с помощта на VBA процедура, която може да бъ-

де извикана с натискане на бутона *Стартиране на ANN* (вж. фиг. 7). Това дава възможност за бързо, ефективно и прецизно интегриране на обучената ANN в друг софтуер за изчисляване на загубите през топлинните мостове на сградата.

	A	B	C	D	E	F	G	H	I
1	Тегловни коефициенти	Thermal-Bridges-IF1&IF3-Weights.txt						Стартиране на ANN	
2	#	a	b	c	d_ext	d_int	$\psi$ ANN result		
3	1	30	20	20	0	0	0.862		
4	2	35	25	25	0	0	0.843		
5	3	35	25	25	3	0	0.173		
6	4	35	25	25	6	0	0.056		
7	5	35	25	25	9	0	0.029		
8	6	35	25	25	12	0	0.018		
9	7	35	25	25	15	0	0.012		
10	8	35	25	25	18	0	0.009		

Фиг. 7. Таблица в лист *Data* на файл *Thermal-Bridges-IF1&IF3-Using.xlsm* с параметри  $a, b, c, d_{ext}$  и  $d_{int}$  и резултат за  $\psi$  от ANN

#### 4.1.3. Използване на ANN в HTML страница чрез JavaScript код

Интегрирането на коефициентите на ANN в друг софтуер е сравнително лесен процес и това е демонстрирано и с JavaScript процедури в HTML страница (фиг. 8) на адрес [26]. Резултатът е бърза и ефективна процедура за изчисляване, която не изисква големи бази данни, нито сложни изчисления, има универсален характер, а и подлежи на актуализиране и усъвършенстване в случай на нови налични данни.

Използваният в демонстрационната HTML страница JavaScript файл с параметрите на обучената ANN е създаден с натискане на бутона *Запис на JavaScript код* (вж. фиг. 3), който активира VBA процедурата *Save\_Weights\_JavaScript()* във файла *Thermal-Bridges-IF1&IF3-Training.xlsm*.

Работна страница на проект за обучение на изкуствена невронна мрежа за изчисляване на  $\Psi$  на линеен топлинен мост по зададени размери  $a, b, c, d_{ext}, d_{int}$ .

Автор: доц. д-р арх. Стоянка М. Иванова, siva\_fce@uacg.bg

$a$  (от 30 до 60):  cm  
 $d_{ext}$  (от 0 до 20):  cm  
 $b$  (от 20 до 50):  cm  
 $d_{int}$  (от 0 до 20):  cm  
 $c$  (от 20 до 25,  $c \leq b$ ):  cm

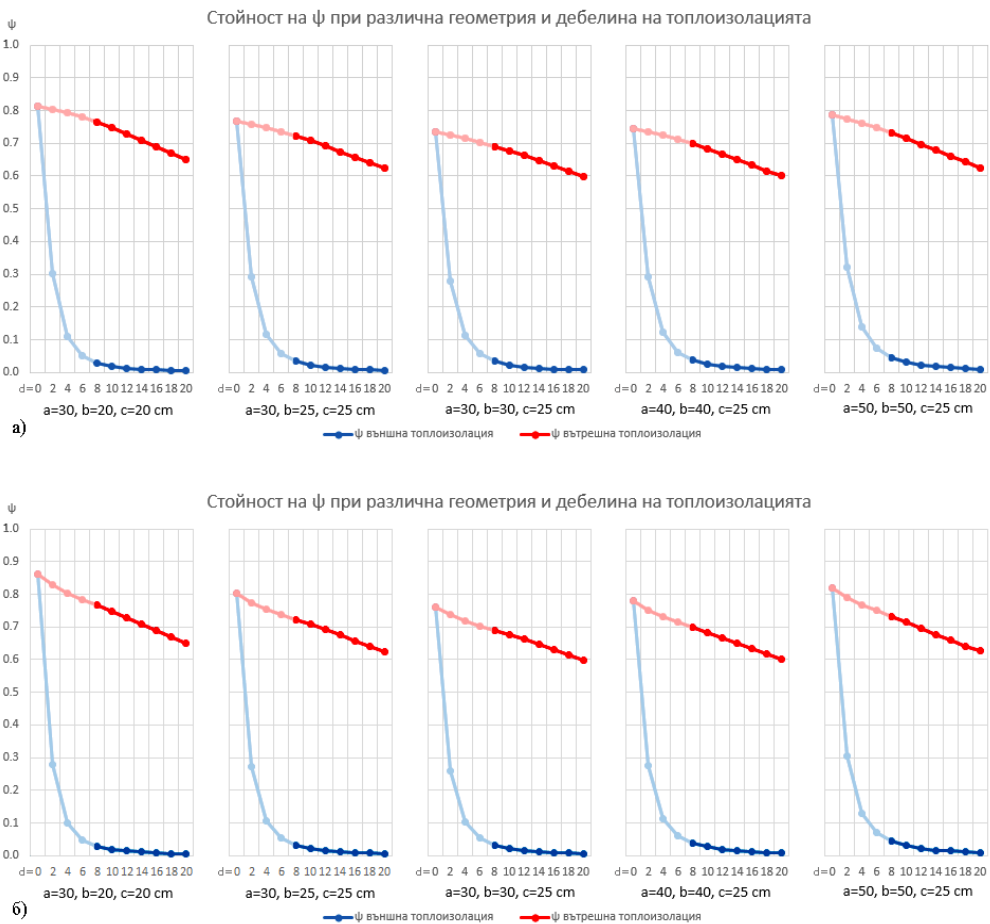
Резултат  $\Psi$  (Psi):  W/(m.K)  
 Резултат U:  W/(m².K)

Фиг. 8. HTML страница [26] с диалогова форма за въвеждане на геометрични параметри на топлинния мост, пояснени във фиг. 2. Коефициентите на обучената невронна мрежа се използват в HTML чрез програмния език JavaScript

Има голямо разнообразие от топлинни мостове и ако определянето на техния линейен коефициент  $\psi$  (външен и/или вътрешен) бъде реализирано чрез ANN, то разработването на серия от HTML страници с JavaScript процедури е едно бързо, лесно и ефективно решение, което да направи достъпни резултатите на тренираните невронни мрежи.

Както се вижда на фиг. 8, в HTML страницата се изчислява и стойността на коефициента за топлопреминаване  $U$ . За тази цел в страницата се използва форм. (4), реализирана с оператори на JavaScript.

Струва си да се отбележи, че обучената ANN разрешава да се изчисли коефициентът  $\psi_e$  в четири различни случая: а) при външна топлоизолация; б) при вътрешна топлоизолация; в) при липса на всякаква топлоизолация; г) при комбинация от външна и вътрешна изолация. Докато коректността на първите два случая е лесно да се провери в каталога на топлинните мостове [15], не така стои въпросът с проверката за правилното придвиждане на резултата в последните два случая, понеже той не се съдържа в каталога и представлява екстраполиране извън известните стойности.



**Фиг. 9.** Стойност на коефициента  $\psi_e$  при различна геометрия на линейния топлинен мост (вж. фиг. 2) и различна дебелина  $d$  на вътрешната и външната топлоизолация. Стойностите са изчислени с обучената ANN във файла *Thermal-Bridges-IF1&IF3-Using.xlsm*. а) БД без запис с  $d = 0$ ; б) БД с добавен запис за  $d = 0$

На фиг. 9а е показана взаимовръзката на коефициента  $\psi_e$  (във вертикална посока) с дебелината  $d$  на топлоизолацията (в хоризонтална посока), разположена външно – в синьо, или вътрешно – в червено, при различни геометрии на топлинния мост. Колкото по-тънка е топлоизолацията, толкова по-висока е стойността на коефициента на линейна топлопроводимост. Стойностите на  $\psi_e$  за дебелина на топлоизолацията  $d \geq 8$  cm, изчислени с ANN, в по-ярко червено и синьо, отговарят напълно на тези в каталога [15], а тези за  $d < 8$  cm (в по-бледи цветове) са предвиждани (екстраполиране) на ANN въз основа на данните, с които е обучена.

Проверките показват, че за стойности извън интервала на обучение (8 до 20 cm) невронната мрежа показва по-висока прецизност за дебелини на топлоизолацията, близки до тези, за които е обучена. Грешката на ANN при определянето на  $\psi_e$  за граничния случай без топлоизолация ( $d = 0$ ), който е най-далеч от интервала на обучение, е около 5,5 – 6% (по данни за  $\psi_e$  от лична кореспонденция с П. Николовски). Една възможна причина за това е, че данните в каталога са закръглени до третия знак след десетичната точка и точността им е недостатъчна за по-прецизно моделиране. Това може да се коригира, като в базата данни за обучение се добавят и тези гранични случаи за  $d = 0$ , и/или бъдат използвани данни за  $\psi_e$  с по-висока точност. За проверка на това предположение ANN е дообучена с добавен ред за  $a = 30$ ,  $b = 20$ ,  $c = 20$  и  $d = 0$ , за да има по-коректен резултат за  $\psi_e$  при липса или при по-тънка топлоизолация (вж. фиг. 9б). Всичко това отново показва колко важно е базата данни за обучение на невронната мрежа да е максимално пълна. Проверката за комбинирана топлоизолация (външна и вътрешна) не може да бъде реализирана чрез наличните данни в каталога, затова засега тази възможност е ограничена в HTML страницата, но ще бъде проучена в бъдеще.

## Изводи

В тази разработка се представя иновативна методика за бързо, ефективно и прецизно определяне на коефициента  $\psi_e$  на линеен топлинен мост, като се използва регресионен анализ и обучена ANN. Демонстрираната методика може да се приложи аналогично за определяне на коефициента  $\psi$  на други типове линейни топлинни мостове. Резултатите могат да се използват за определяне на топлинните загуби на сградите през топлинните мостове по време на студения сезон. Коректното изчисляване на тези топлинни загуби има голямо значение за по-адекватно проектиране на мерките за енергийна ефективност.

Приносителите на настоящата публикация са, както следва:

- разработката показва, че ANN може да се използва за определяне на линейния коефициент на топлопроводимост  $\psi_e$  и че има потенциал в по-нататъшното развитие на концепцията, така че в изследването да бъдат включени и други разновидности на линейни топлинни мостове;
- стъпка по стъпка е показано как може да се реализира обучението на изкуствена невронна мрежа с обратно разпространение на грешката с помощта на VBA в средата на MS Excel;
- показани са няколко примера как може да бъде използвана обучена невронна мрежа – чрез формули в лист в MS Excel, чрез макроси на VBA и чрез JavaScript в HTML страница;



- публикацията включва богат и подробен архив от файлове, с помощта на които всеки може да повтори проучването, в това число и обучението на ANN или да го адаптира към други задачи.

Бъдеща работа предстои в следните насоки:

- 1) разширяване на базата данни за обучение на невронната мрежа с междинни стойности на размерите на конструктивните елементи – греди и зидана стена;
- 2) разширяване на дефиниционната област на всички входни данни;
- 3) добавяне на коефициента на топлопроводност  $\lambda$  на участващите в конструкцията на топлинния мост пластове и елементи, към входните данни;
- 4) обучение на други ANN за определяне на коефициента  $\psi$  на други типове топлинни мостове;
- 5) обобщаване на различни типове топлинни мостове в по-обща категории, когато е възможно.

## ЛИТЕРАТУРА

1. *Chobanov, Pl.* Energy efficiency in construction. UACEG – Sofia, 2016.
2. BDS EN ISO 10211:2008. Toplinni mostove v stroitelni konstruktsii. Toplinni pototsi i povarhnostni temperaturi. Podrobni metodi za izchislyavane.
3. PASSIPEDIA > What defines thermal bridge free design? [https://passipedia.org/basics/building\\_physics\\_-\\_basics/what\\_defines\\_thermal\\_bridge\\_free\\_design](https://passipedia.org/basics/building_physics_-_basics/what_defines_thermal_bridge_free_design), poseten na 22.03.2022.
4. European standard ISO 6946:2017(en), Building components and building elements.
5. BISCO – Physibel. <https://www.physibel.be/en/products/bisco>, poseten na 22.03.2022.
6. ISO 10211:2017 Thermal bridges in building construction – Heat flows and surface temperatures – Detailed calculations.
7. COMSOL Multiphysics, <https://www.comsol.com/>, poseten na 22.03.2022.
8. COMSOL Reference Manual. [https://doc.comsol.com/5.4/doc/com.comsol.help.comsol/COMSOL\\_ReferenceManual.pdf](https://doc.comsol.com/5.4/doc/com.comsol.help.comsol/COMSOL_ReferenceManual.pdf).
9. TRISCO – Physibel. <https://www.physibel.be/en/products/trisco>, poseten na 22.03.2022.
10. Flixo, <https://www.flixo.com/>, poseten na 22.03.2022.
11. *Chobanov, Pl.* Simulation approach for analysis and evaluation of the thermal insulation capacity of buildings. PhD Thesis, Sofia, June 2005.
12. *Chobanov, Pl.* Analysis of thermal bridges in seismic regions – column in the wall. // Annual of the University of architecture, civil engineering and geodesy, Sofia, Volume 49, 2016, Issue 2, 23-30.
13. *Chobanov, Pl.* Analysis of thermal bridges in seismic regions – column in the wall corner. // Annual of the University of architecture, civil engineering and geodesy, Sofia, Volume 49, 2016, Issue 2, 31-40.

14. ISO TC 163/SC 2, ISO/FDIS 14683:2007(E) Thermal bridges in building construction – Linear thermal transmittance – Simplified methods and default values, [http://www.iuav.it/Ateneo1/docenti/architetu/docenti-st/Fabio-Pero/materiali-/corso-tecn/appli-03-14683-ISO\\_FDIS-ponti-termici.pdf](http://www.iuav.it/Ateneo1/docenti/architetu/docenti-st/Fabio-Pero/materiali-/corso-tecn/appli-03-14683-ISO_FDIS-ponti-termici.pdf), poseten na 22.03.2022.

15. *Nikolovski, P.* Katalog na linearni toplinski mostovi vo zgradi vo seizmichki regioni. Komora na ovlasteni arhitekti i ovlasteni inzheneri na Republika Makedonija, Skopje, 2017.

16. *Nikolovski, P.* Toplinski mostovi vo gradezhnite konstruktсии, Institut za standardizatsija na Republika Makedonija, Skopje, 2012.

17. Wikipedia: Regression analysis, [https://en.wikipedia.org/wiki/Regression\\_analysis](https://en.wikipedia.org/wiki/Regression_analysis), poseten na 22.03.2022.

18. *Ivanova, S. M., Yakov, V. N.* Overview of the use of artificial neural networks for architectural and construction applications. // V international scientific conference High Technologies. Business. Society 2020, 09-12.03.2020, Winter Resort Borovets, Bulgaria, 44-47.

19. *Dimitrova, S.* Application of artificial intelligence in architectural design. // In Proceedings of the First Department Scientific Conference at the Department of Industrial and Agricultural Buildings at the Architectural Faculty of UACEG – Sofia, 2022.

20. *Goh, A. T. C.* Back-propagation neural networks for modeling complex systems. // Artificial Intelligence in Engineering, 9 (1995), 143-151.

21. *Hammerstrom, D.* Working with neural networks. // IEEE Spectrum, July (1993), 46-53.

22. *Csáji, B. C.* Approximation with Artificial Neural Networks. // MSc Thesis, Faculty of Sciences; Eötvös Loránd University, Hungary, 2001.

23. Software for drawing neural network diagrams. <https://alexlenail.me/NN-SVG/>, poseten na 22.03.2022.

24. *Ivanova, St.* Archive of all data files and programs to this publication. [https://uacg.bg/filebank/att\\_22239.zip](https://uacg.bg/filebank/att_22239.zip).

25. Neural Network Toolbox – MatLab. <https://www.mathworks.com/matlabcentral/fileexchange/71468-neural-network-toolbox>, poseten na 22.03.2022.

26. *Ivanova, St.* Calculation of Psi of a linear thermal bridge according to given dimensions a, b, c, d\_ext, d\_int – HTML page with JavaScript code: [https://ait.uacg.bg/EE/Thermal\\_Bridges/Thermal\\_Bridges-IF1&IF3-v1.htm](https://ait.uacg.bg/EE/Thermal_Bridges/Thermal_Bridges-IF1&IF3-v1.htm).

# ESTIMATION OF LINEAR THERMAL TRANSMITTANCE OF THERMAL BRIDGES IN SEISMIC AREAS THROUGH AN ARTIFICIAL NEURAL NETWORK

St. Ivanova<sup>1</sup>

*Keywords:* MS Excel, VBA, regression analysis, heat losses, training, HTML, JavaScript

## ABSTRACT

Losses from heat transfer during the so-called thermal bridges represent a significant part of the total heat loss of buildings. Therefore, the calculation of the coefficient of linear thermal transmittance  $\psi$  is of great importance. Due to the variety of building structures and solutions that lead to different combinations of geometric and physical parameters of thermal bridges, expensive specialized software is used to model the heat fluxes through building structures and to estimate the coefficient of linear thermal transmittance  $\psi$ . Another possible solution is to use catalogs of thermal bridges, which contain sets of geometric data and their corresponding values of  $\psi$ . This paper presents an innovative methodology for fast, efficient, and accurate estimation of the transmittance coefficient  $\psi$  of linear thermal bridges, using regression analysis and trained ANN.

---

<sup>1</sup> Stoyanka Ivanova, Assoc. Prof. Dr. Arch., Dept. "Computer-Aided Engineering", UACEG, 1 H. Smirnovski Blvd., Sofia 1046, e-mail: siva\_fce@uacg.bg