

SZENT ISTVÁN EGYETEM

Napkollektoros rendszerek modellezése  
neurális hálóval

Doktori értekezés tézisei

Géczyné Víg Piroska

Gödöllő  
2007

**A doktori iskola  
megnevezése:**

Műszaki Tudományi Doktori Iskola

**tudományága:**

Agrárenergetika

**vezetője:**

Dr. Szendrő Péter  
egyetemi tanár, DSc  
SZIE, Gépészmérnöki Kar,  
Mechanikai és Géptani Intézet

**témavezető:**

Dr. Farkas István  
egyetemi tanár, DSc  
SZIE, Gépészmérnöki Kar,  
Környezetipari Rendszerek Intézet

.....  
az iskolavezető jóváhagyása

.....  
a témavezető jóváhagyása

## TARTALOMJEGYZÉK

1. BEVEZETÉS.....	4
<b>1.1. A választott témakör jelentősége</b> .....	4
<b>1.2. Célkitűzések</b> .....	5
2. ANYAG ÉS MÓDSZER.....	6
<b>2.1. A vizsgált szoláris vízmelegítő rendszer</b> .....	6
<b>2.2. NN modellezési módszer</b> .....	7
3. EREDMÉNYEK.....	9
<b>3.1. Szoláris potenciál modellezése NN segítségével</b> .....	9
3.1.1. <i>Statikus modell</i> .....	9
3.1.2. <i>Prediktív modell</i> .....	10
<b>3.2. Síkkollektor NN modellje</b> .....	12
3.2.1. <i>Konstans tömegáramú modell</i> .....	12
3.2.2. <i>Általánosított modell</i> .....	13
<b>3.3. Szoláris vízmelegítő rendszerek NN modellje</b> .....	14
<b>3.4. Szoláris háztartási vízmelegítő rendszer NN modellje mért adatok alapján</b> .....	15
4. ÚJ TUDOMÁNYOS EREDMÉNYEK.....	20
5. KÖVETKEZTETÉSEK ÉS JAVASLATOK.....	22
6. ÖSSZEFOGLALÁS.....	23
7. SZAKMAI PUBLIKÁCIÓK JEGYZÉKE.....	24

## 1. BEVEZETÉS

### 1.1. A választott témakör jelentősége

Az Európai Unió célkitűzése, hogy a megújuló energiahordozó-felhasználás részarányát 2010-ig 12%-ra, a megújulókkal termelt villamos energia részarányát pedig 22,1%-ra növeljék (2001/77/EK irányelv). Magyarország is részt vállalt ebben, a tervezett energiahordozó felhasználás hazai stratégiája szerint a zöld villamos energia arányt 2010-re 6,5%, 2013-ra 11,4 %-ra szükséges növelni. Ezen kívül az összes megújuló energia részarányát a 2005. évi 5,3%-ról 2010-re legalább 8,2%-ra, 2013-ra 14%-ra kívánják növelni a hazai energiafelhasználáson belül. Az EU 2007. márciusi brüsszeli találkozóján pedig az a döntés született, hogy a 27 tagállam átlagában el kell érni a 20% megújulóenergia részarányt. Ezek realizálásához szeretnék munkámmal hozzájárulni.

Egy-egy területen a földrajzi és gazdasági adottságok mérvadóak abban, hogy melyik megújuló energiatípus alkalmazása a hatékonyabb. Magyarországon az egész éves, teljes sugárzás-jövedelem 1170-1300 kWh/(m<sup>2</sup>év) értékű, így hazánk éghajlati adottságai kedvezőnek mondhatók a napenergia felhasználását illetően. A napenergia passzív felhasználása építészeti megoldásokban jelentkezik. Az aktív hasznosítás fotovillamos rendszerek segítségével a napenergiából villamos energiát vagy napkollektorok segítségével hőenergiát nyerve valósul meg. Jelenleg a fototermikus rendszerek közül széles körben leginkább a síkkollektoros rendszerek elterjedésére van esély kedvező árak miatt. Ezek leggyakoribb felhasználási területe a használati melegvíz készítés, és fűtés rásegítés, ill. ipari méretben uszodavíz melegítése, mezőgazdasági termények szárítása.

A SZIE Fizika és Folyamatirányítási Tanszékén (SZIE FFT) a napenergia hasznosítás témakörben folyó kutatások új technológiák kidolgozását és a hatékonyság növelését célozzák. Ezen kutatások része az általam tanulmányozott és továbbfejlesztett síkkollektoros vízmelegítő rendszer vizsgálata.

A megépítendő rendszer működtetéséhez modellek készíthetők melyek szimulálhatják a rendszer viselkedését, hatékony segítséget nyújtva a rendszer összetevőinek optimális megválasztásához, a fő elemeinek a méretezéséhez és a minél gazdaságosabb üzemeltetéshez. A síkkollektoros rendszer sok tényező által befolyásolt, bonyolult dinamikai rendszer, egyes részeit és a teljes rendszer viselkedését leíró különböző modellek léteznek.

Amennyiben sok mérési adat áll rendelkezésre, alternatívaként kínálkozik a neurális hálós (NN) modellezés. Ez különösen előnyös olyan rendszerek esetén amelyekre nincs, vagy nagyon bonyolult a fizikai alapú modell. Azon cél eléréséhez, hogy a rendszerekről a műszaki életben hasznosítható ismereteket szerezzek, eszközként - a vizsgált problémák esetén is ígéretesnek mutató - NN modellezést választottam. A síkkollektoros vízmelegítő rendszer fő elemeire, a síkkollektorra és a hő tárolását megvalósító eszközökre (tárolókra) koncentrálni szeretném a jelen munkában bemutatni a neurális hálós vizsgálat segítségével nyert modelleket és eredményeket.

## 1.2. Célkitűzések

Jelen kutatási munkám célja, hogy a síkkollektoros vízmelegítő rendszer kollektorának működésére és a tárolójában a meteorológiai és fogyasztási viszonyok miatt kialakuló termikus viselkedés leírására neurális hálós modellel dolgozzak ki. A modell segítségével nyert eredmények lehetőséget nyújtanak az ilyen rendszerek szimulációjához, alkalmazhatók szabályozásnál és tervezési, méretezési feladatok megoldásánál.

Fontos cél, hogy minél olcsóbb, nagyobb hatásfokú rendszerek kerüljenek felhasználásra, illetve hogy a rendszerek szabályozását a nagyobb energianyereség szempontjából optimalizáljuk és ezt minél egyszerűbben valósítsuk meg. A dolgozatommal ezekhez kívánok hozzájárulni, neurális hálós modellek segítségével nyert eredményekkel.

A konkrét kutatási célok a következők:

1. Meteorológiai adatok NN modellezése.
2. Síkkollektor termikus viselkedésének neurális hálós modellezése.
3. A SZIE FFT-n található síkkollektoros vízmelegítő rendszer és az egyetemi strand területén található a szomszédos óvoda vizét melegítő síkkollektoros rendszer tárolójában a napsugárzás, a környezet hőmérsékletének és a fogyasztásnak függvényében a tárolóban kialakuló réteghőmérséklet meghatározására szolgáló fizikai alapú modellek elkészítése a TRNSYS szoftver segítségével.
4. A síkkollektoros rendszerek neurális hálós modelljének kidolgozása, mely lényegesen egyszerűbb, mint a fizikai alapú modell, és kellő pontossággal leírja az időjárás és a fogyasztás következtében a tartályokban kialakuló termikus viszonyokat.
5. A SZIE FFT-n található síkkollektoros rendszer tárolójába speciális, a termikus rétegződés kialakulását és fennmaradását elősegítő belső hőcserélő elkészítése és a réteghőmérsékletek mérhetőségének kialakítása.
6. A megépített rendszerre vonatkozóan különböző meteorológiai viszonyok és fogyasztási szituációk esetén a tartály termikus viselkedésének vizsgálata mérésekkel.
7. A szoláris vízmelegítő rendszerekre kidolgozott neurális hálós modell mérési adatok alapján történő finomítása és validálása. Az NN modell és a fizikai alapú modell eredményeinek mérési adatokkal történő összevetése.
8. Az NN modell érvényességi határainak vizsgálata.
9. Az NN modellek elemzéséből kiolvasható összefüggések feltárása.
10. További alkalmazási lehetőségek vizsgálata.

## 2. ANYAG ÉS MÓDSZER

Ebben a fejezetben bemutatom az általam vizsgált szoláris vízmelegítő rendszert, részletezem, hogy milyen fizikai mennyiségeket a rendszer mely pontjain mértem, külön választva a már korábban meglévő és a jelen munkához kialakított mérési lehetőségeket. Továbbá itt ismertetem az általam alkalmazott neurális hálós modellezési módszert.


## 2.1. A vizsgált szoláris vízmelegítő rendszer

A vizsgált oktatási és demonstrációs céllal épített napkollektoros rendszerrel – amely a SZIE Fizika és Folyamatirányítási Tanszékén működik - a kollektor által termelt hő egy tároló vizét melegíti.

Az általam vizsgált termikus folyamatok nyomonkövetésére és a rendszer szabályozásához a következő jellemzők méréseire volt szükség:

$T_{in}$	kollektorba belépő szolárfolyadék hőmérséklete
$T_{out}$	kollektorból kilépő szolárfolyadék hőmérséklete
$T_{wc}$	kollektor környezetének hőmérséklete
$T_{wt}$	tároló környezetének hőmérséklete
$T_{be}$	tárolóba utánpótlásként érkező víz hőmérséklete
$T_{ki}$	fogyasztáskor a tárolóból kivett víz hőmérséklete
$I$	a kollektor egységnyi felületét ért globál sugárzás
$\dot{m}_L$	a fogyasztás tömegárama
$\dot{m}_c$	szolárkörbeli tömegáram

A vizsgált rendszerrészt a kialakított mérési lehetőségekkel az 1. ábra mutatja.



1. ábra A vizsgált rendszerrész a mérőhelyekkel

A tárolókban a termikus rétegződés általában csak részben valósul meg, bár energetikailag ez lenne a kedvezőbb. Én speciális hőcserélő beiktatásával igyekeztem a vizsgált melegvízes tárolóban a tökéletesebb rétegződés kialakulását

és fennmaradását segíteni és 8 egyenlő vastagságú réteg középpontában megvalósítottam a rétegek hőmérsékleteinek mérési lehetőségét.

A hőcserélő 1 mm falvastagságú 15 mm átmérőjű vörösréz csőből készített 13 menetes csőkígyó. A jeladók vezetőkei a hőcserélő szimmetria tengelyén átvezetett rézcsövön keresztül jutnak a tárolóba. A 250 mm magas hőcserélő egy 170 mm átmérőjű, 5 mm vastag sárgaréz alaplagra lett integrálva, amely egyben a tároló záróeleme is. A hőcserélőre jól illeszkedő rozsdamentes acél henger biztosítja a felmelegítendő hidegvíz szabályozott beáramlását a hőcserélőbe, mely a primer közeg által szállított hő átadása utáni konvekciós áramlással működik.

A hőcserélő hengerpalástjának folytatásaként egy leszűkített rézcsőben áramlik tovább a hőcserélő által felmelegített víz a bojler felső részébe.



A konvekciós elven működő áramlási „folyosó” 10 mm vastagságú szilikon-kaucsuk zártcellás habszigetelést kapott (2. ábra). A hőcserélő rendszer ilyen módon történő kialakítása optimális feltételeket biztosít a tárolóbeli közegben a termikus rétegződés kialakulásához.

2. ábra A beépített hőcserélő

A hőmérsékletmérés termoelemekkel valósult meg, melyhez ideális méretű érzékelő foglalatot határoztam meg figyelembe véve az elvárt vízmentes szigetelést, a hőtehetlenségeket és a termoelemek rögzíthetőségét.

Elvégeztem a mérőrendszer kalibrálását amely esetemben különösen lényeges, hiszen az NN modellezésnél csak mérési adatokra támaszkodom. Az adatgyűjtő rendszer ADAM modulokból épül fel, melyek kapcsolatban vannak egymással és a központi számítógéppel. A jelek konvertálása és a rendszer szabályozása is ADAM modulokon keresztül történik.

### 2.2. NN modellezési módszer

A biológiai neurális hálózatok adták az alapötletet a mesterséges neurális hálózatok megvalósításához. Az agy tulajdonságai közül elsősorban a tanulóképesség, a gyorsaság és a nagy hibatűrőképesség melyeket a mesterséges hálózatok átörökítettek.

A mesterséges neuron az agyi neuron másolata. A súlyozott bemenetet és egy konstansra választott bemenetet (bias) egy összegzés és valamilyen általában nem lineáris függvény követ. Ennek eredményeként születik a kimenet. A neuron rendelkezhet lokális memóriával is, amely pl. késleltetéseken, visszacsatolásokon keresztül érhető el.

Az NN-ben a neuronok ugyanolyan vagy hasonló típusú műveleteket végeznek a többiektől függetlenül, sok másik neuronnal lehetnek összekapcsolva és a háló tanulni is képes.

A tanítási ill. tanulási folyamatra 3 alapvetően különböző lehetőség van: ellenőrzött, nem ellenőrzött és analitikus módok.

Ellenőrzött tanulás esetén összetartozó be- és kimeneti adatpárok állnak rendelkezésre és a cél az, hogy a tanítandó hálózat működése minél jobban megközelítse a vizsgált rendszer működését. Ez a megfelelő struktúra kiválasztásával és a paramétereinek beállításával érhető el. Tanításkor egy adott bemenetnél a háló választ össze tudjuk hasonlítani a kívánt válasszal, és a keletkező hiba felhasználható a hálózat tanításánál. Kritériumfüggvényként használható pl. az eltérésnégyzetek összege, melynek minimumát keressük a súly és bias értékek függvényében.

A napkollektoros rendszerekkel kapcsolatos vizsgálatoknál ellenőrzött tanulású hálózatok jöhetnek szóba és ezek közül - a problémákból adódóan – főként az MLP (Multi Layer Perceptron) típust sikerült eredményesen alkalmazni. Ennek tanulásalgoritmus a hibavisszaterjesztés tanuló algoritmus (backpropagation), melynek különböző a szélsőérték keresést gyorsító változatai közül a Levenberg-Marquardt algoritmust alkalmaztam a modellek kidolgozásánál.

Modellezés főbb lépései - adatok gyűjtése, struktúra tervezés, tanítás, validálás - kiegészülhetnek teszt, érvényességi határok vizsgálata és szimuláció lépésekkel.

Az általam elkészített modellek a MATLAB szoftver és Neural Network Toolboxának felhasználásával készültek.

Az NN modellek előnyei a fizikai alapú modellekkel szemben a dolgozatban bemutatásra került modelleknél is megfigyelhetőek:

- tetszőleges viselkedést képes megtanulni, (azonban a kellő pontosságú becsléshez sok mintára van szüksége),
- lényegesen egyszerűbb, mint a problémát leíró fizikai alapú modell, tehát alkalmazása pl. a rendszer szabályozása során előnyöket biztosít az üzemeltető számára,
- ha a modell kidolgozása csak mérési adatokra épül, kikerülhet a rendszer paramétereinek (hővezetési, hőátadási, hőveszteségi, geometriai, stb. jellemzők) sokszor csak bonyolult méréssel lehetséges meghatározása,
- míg a fizikai alapú modellek elhanyagolásokat tartalmaznak, az NN modell - amennyiben csak mérési adatokra épül -, a mérési pontosságon belül a befolyásoló tényezők mindegyikének a hatását közvetlenül vagy közvetve figyelembe veszi.

Ugyanakkor meg kell említeni, hogy ha a modellezett rendszerben valamilyen változás történik, ez a fizikai alapú modelleknél rendszerint egyszerűen kezelhető, azonban az NN modellnél újabb mérések alapján szükség van a paraméterek újabb identifikációjára, mielőtt a modellt megbízhatóan alkalmazhatnánk.



## 3. EREDMÉNYEK

A dolgozat azon eredményeit ismertetem itt röviden, melyekhez kapcsolódóan téziseket fogalmaztam meg.

## 3.1. Szoláris potenciál modellezése NN segítségével


A szoláris rendszerek alkalmazhatóságának eldöntéséhez és méretezéséhez ismernünk kell az adott földrajzi helyen nyerhető szoláris potenciált. Ennek meghatározására két alapvetően különböző típusú NN modellt vizsgáltam. Az első egy általam statikusnak nevezett olyan neurális háló, amely az adott földrajzi helyen adott nap és óra értékhez várható hőmérséklet és sugárzás értéket becsül. A második pedig egy általam prediktívnek nevezett modell, amely az előző órák adatai alapján becsüli meg a következő órára várható sugárzás és hőmérséklet értéket.

## 3.1.1. Statikus modell

Az NN struktúra tervezésénél és a tanításnál az 1999., 2000. és 2001. év júniusi adatai kerültek felhasználásra.

A modell bemenő adatai a júniusi nap és óra, kimenő értékek pedig a sugárzás és a hőmérséklet.

A különböző hálótípusok közül jó közelítést adott az ún. általánosított regressziós (generalized regression) hálótípus, azonban ennek jellemzője a nagy neuronszám, mivel az első rétegben annyi neuronnal dolgozik, amennyi a bemenő adatsorok száma. Ennél kevésbé pontos, de elfogadható közelítést adott az előre vezetéssel (feed-forward) backpropagation tanulóalgoritmuson alapuló hálótípus, a 3. ábra szerint 13 tangens-szigmoid átviteli függvényű neuronnal a rejtett rétegben



3. ábra A legjobb közelítést adó NN struktúrája MATLAB jelölésrendszerrel

A vizsgálatok során azt tapasztaltam, hogy több réteg illetve visszacsatolás alkalmazása esetén sem adódott jobb közelítés, így ezzel a struktúrával dolgoztam a továbbiakban.

A tanulás során a hőmérséklet adatoknál az átlagos eltérés  $3,46\text{ }^{\circ}\text{C}$ , a sugárzásnál  $124,91\text{ W/m}^2$  volt a teljes tanuló adatsorra vonatkozóan.

A validálásnál a neurális hálós eredményt a tanítás során fel nem használt adatsorokkal vettem össze: az I. vizsgálat során a 2002. év adataival, a II. vizsgálat során 2006-ban mért adatokkal.

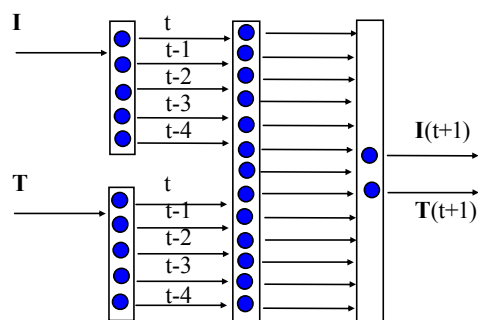
Összegzésként megállapítható, hogy sikerült a problémához egy statikus NN struktúrát találni, ami a hőmérsékletre 18%, a sugárzásra 30% pontos becslést ad. A tanításnál több év adatát felhasználva várhatjuk, hogy ez a neurális háló más módszerekkel számított értékekhez jól közelítő értékeket ad. A struktúra alkalmas az adott helyszínen más hónap hőmérséklet és sugárzás adatainak becslésére is, ha erre tanítjuk meg, illetve alkalmas más földrajzi helyre vonatkozóan sugárzási és hőmérséklet adatok becslésére, ha a tanításnál arra a helyre vonatkozó adatokat használunk.

### 3.1.2. Prediktív modell

Az ún. prediktív NN modell az előző néhány órában mért sugárzás és hőmérséklet adatokból, tanult minták alapján ad becslést a következő órában várható sugárzás és hőmérséklet értékekre.

A statikus modell kidolgozásánál használt mérési adatsorokat alkalmaztam ezen modellezés során is, azonban most úgy határoztam meg az adatsorokat, hogy egy adathoz legalább az előtte lévő 8 óra adatai is rendelkezésre álljanak.

Először meg kellett vizsgálni, hogy hány megelőző óra adatából lehet legjobb becslést tenni. Különböző késleltetésekkel (2-8 óra) a rejtett rétegben a statikus modellbelihez hasonlóan 13 tansig ill. a kimeneti rétegben 2 lineáris átviteli függvényű neuron alkalmazásával kapott átlagos eltérésértékeket vizsgálva kaptam, hogy a megelőző 5 óra adataiból számított értékek esetén várható a legkisebb eltérést a mért és becsült értékek között. Túl kevés megelőző adat esetén bizonytalanná, túl sok megelőző adatnál pedig túl határozottá válik a modell. A prediktív modell struktúráját a 4. ábra mutatja.



4. ábra A prediktív modell struktúrája

A statikus és prediktív modellek esetén a sugárzás és hőmérsékletre vonatkozó átlagos eltéréseket tünteti fel a tanulásra és a két validálásra az 1. táblázat.

1. táblázat A statikus és prediktív modell átlagos eltérései

	Statikus modell		Prediktív modell	
	I [W/m <sup>2</sup> ]	T [°C]	I [W/m <sup>2</sup> ]	T [°C]
<b>Tanítás</b>	124,91	3,46	81,55	3,42
<b>Validálás1</b>	120,36	3,19	96,95	3,68
<b>Validálás2</b>	104,28	2,95	69,12	2,98

A prediktív modell mind a tanulásnál, mind a validálásoknál a sugárzás értékekre 30 W/m<sup>2</sup> körüli értékkel pontosabb eredményt adott, mint a statikus modell. A hőmérséklet becslésében nincs lényeges különbség a két modell eredménye között. Normalizált adatsorokra elvégeztem a bemeneti és rétegsúlyok analízisét.


A 13x10 bemeneti és 2x13 rétegsúlyok mátrixainak értékeit vizsgálva azt tapasztaltam, hogy mind a 13 neuron kimeneténél a sugárzáshoz tartozó súlyok nagyobbak voltak, mint a hőmérsékletéhez tartozók. A súlyok aránya 2,7-30 szorosig terjed, vagyis a sugárzás dominanciája a súlymátrix értékeiből következik.

Ez adta az ötletet, hogy külön sugárzásra és külön hőmérsékletre kidolgozott prediktív NN modellek alkalmazásával próbáljam tovább csökkenteni az átlagos eltérést.

Ugyanazokat a mérési adatokat használva a tanításnál ill. alkalmazva a validálásnál a következőket tapasztaltam:

A sugárzás adatokra vonatkozóan a tanítás 95,85 W/m<sup>2</sup> átlagos eltérést a 2000. évi validálás 74,71 W/m<sup>2</sup>, míg a 2006-os adatsorra 70,64 W/m<sup>2</sup> adódott, tehát nem lett számottevően pontosabb a sugárzásadatok becslése.

Az előbbihez hasonló modellt elkészítve a hőmérsékletre viszont a tanulás eredménye 0,92 °C, a 2000. évi validálás 0,78 °C, a 2006-os adatokra pedig 1,03 °C volt (5. ábra).



5. ábra Validálás eredménye 2006. évi adatsorra

Tehát a hiba mind a tanulásnál, mind a validálásnál lényegesen csökkent, a becslés pontossága 5%. Ennek magyarázata, az első prediktív modell pontosságát a nagyobb bizonytalanságú sugárzás pontossága határozta meg és amikor csak a sugárzás szerepelt ennek bizonytalansága nem csökken számottevően. Ugyanakkor a hőmérsékletet magában vizsgálva számottevően javult a becslés pontossága.

A bemutatott modellek részét alkották egy PV rendszer méretezésére készített hibrid (NN + fizikai alapú) modellnek.

A prediktív modellek előtérbe kerülnek a nagy holtidejű rendszerek szabályozásánál, és a fejezet tanulságai szerint, ha NN alapú modellt szeretnének alkalmazni, a pontosság növelhető, ha külön-külön alkalmazunk NN modellt a hőmérséklet és sugárzás adatok becslésre.

### 3.2. Síkkollektor NN modellje

A kidolgozott 2 modell közül az első a kollektorok alaptípusaira folyamatos szolárköri működés esetén érvényes, míg a második a kollektorköri változó tömegáramot is figyelembe tudja venni.

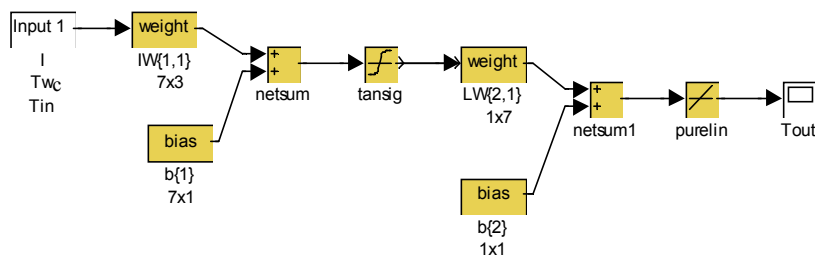
#### 3.2.1. Konstans tömegáramú modell

A cél egy olyan NN meghatározása, amely a napsugárzás, a környezet hőmérséklete, és a kollektorba belépő folyadék hőmérséklete adataiból az adott kollektor esetén megbecsüli a kollektorból kilépő folyadék hőmérsékletét.

3 féle síkkollektorra álltak rendelkezésre mérési adatok (levegős, folyadék munkaközegű és hőtárolós kollektor). Mindhárom geometriája megegyező. Ezen kollektorokra vonatkozó mérési adatok adták a kiinduló alapot az NN modellezéshez.

Mivel kevés mérési adat állt rendelkezésre, a mérési eredményeket jól közelítő Hottel-Whillier (H-W) modell segítségével számított adatokat is felhasználtam az NN struktúra tervezésénél. A három kollektorra rendelkezésre álló adatsorok alapján a H-W modell felhasználásával elvégzett paraméteridentifikációval meghatároztam a kollektorok hőátviteli paramétereit. Ezen paraméterek felhasználásával a Matlab+Simulink szoftver segítségével elkészítettem kollektormodellekkel a mérési adatok közé közbülső adatokat generáltam. Ezen számított adatokat és a mért értékeket használtam az NN struktúra tervezésnél.

A rejtett rétegében 7 neuront tartalmazó NN adott megfelelő közelítést. A problémát leíró neurális hálót mutatja a 6. ábra.



6. ábra Az NN a MATLAB jelölésrendszeréve

ahol:  $IW$  (input weight) bemeneti-,  $LW$  (layer weight) réteg-súlymátrixok;  $b\{1\}$ ,  $b\{2\}$  biasvektorok; tansig, purelin átviteli függvények.

Ez a struktúra alkalmas volt mindhárom kollektor termikus viselkedésének leírására.


Az alkalmazás a Tanszéken található síkkollektorra történt a meteorológiai adatgyűjtő rendszer által mért, és a síkkollektorra vonatkozó mérési adatok felhasználásával.

A kollektor működésének modellezésekor olyan szakaszokat kellett választani, amelyeknél a szivattyú folyamatosan működik, konstans tömegáramot biztosítva a kollektornál. A feltételnek megfelelő szakaszok a tartály kiürítését követő néhány óras napközbeni időszakok. Az átlagos eltérés a mért és NN segítségével kapott  $T_{out}$  értékek között  $0,59\text{ }^{\circ}\text{C}$ .

#### 3.2.2. Általánosított modell

A fent vizsgált síkkollektorra a 2006. évi percnként rendelkezésre álló adatok alapján olyan NN modellt dolgoztam ki, amely az előző probléma bemenő adatai mellett a kollektorköri tömegáramot is figyelembe véve, a kollektorból kilépő szolárfolyadék hőmérsékletének becslésére folyamatosan alkalmas.


A problémát egy 2 rétegű, a rejtett rétegében 11 db tangens-szigmoid a kimeneti rétegében pedig 1 db lineáris átviteli függvényű neuront tartalmazó NN írja le (7. ábra).



7. ábra A síkkollektor általánosított NN modellje

A tanulás során a modell a mérési adatokat  $0,9\text{ }^{\circ}\text{C}$  átlagos pontossággal tudta megtanulni.

A validálást elvégezve  $1,6\text{ }^{\circ}\text{C}$  átlagos eltérés adódott. A validálás eredményét egy 2 napos időtartamra a 8. ábra mutatja.



8. ábra Az általánosított modell validálási eredménye (2006. szept. 1-2.)

A nagyobb eltérés oka, hogy itt a kollektorkör szabályozásából adódóan a kikapcsolt állapotból a folyamatos működésre való áttérésig (és a fordított folyamatnál) többször lezajló ki-bekapcsolás tranziens jelenségét a háló nem tudta olyan pontosan megtanulni, mint a folyamatos ki- ill. bekapcsolt állapotnál megfigyelhető viselkedést.

### 3.3. Szoláris vízmelegítő rendszerek NN modellje

Olyan NN struktúra kidolgozását tűztem ki célul, amely különböző szoláris vízmelegítő rendszereknél a réteghőmérsékleteket képes meghatározni.

A modell kidolgozása két szoláris vízmelegítő rendszerre történt, a háztartási méretű - 2.1. pontban részletezett - és a közepes méretű, óvodai (az egyetemi strand területén található a kollektorai, és az egyetemi óvoda használati melegvizének előmelegítésére szolgál) rendszerre. A háztartási rendszer tárolójának átalakításával a termikus rétegződés kialakulását és fennmaradását elősegítettem, az óvodai rendszer pedig szolártárolóval rendelkezik.

A réteghőmérsékletek mérésére csak a háztartási rendszernél volt módom, így az alap NN modell kidolgozásánál a rendszerek TRNSYS szoftver segítségével elkészített fizikai alapú modelljeinek segítségével becsült réteghőmérsékleteket használtam.


Az NN a tartály 8 egyenlő vastagságú rétegének aktuális hőmérsékletéből valamint a mérhető átlagos napsugárzás, hőmérséklet, valamint a fogyasztás és a kollektorkör tömegáramai alapján becsüli meg a rétegek hőmérsékletét a következő órában.

Az NN modellezés során a következő adatokat használtam:

- Meteorológiai adatok: a helyszínen található meteorológiai állomás által mért adatok.
- Fogyasztási profilok a háztartási rendszernél egy átlagos 4 fős család fogyasztási szokásait, a közepes méretűnél pedig az óvoda melegvíz fogyasztását figyelembe véve kerültek meghatározásra.

- Kezdeti és peremfeltételek: kiűrtett tároló (minden réteg hőmérséklete 15 °C), az utánpótlásul érkező víz hőmérséklete 15 °C, a tároló környezetének hőmérséklete állandó, 21 °C.
- A kidolgozásra kerülő NN modellhez a termikusan rétegzettnek feltételezett tárolók réteghőmérséklet adatait a rendszerekre a TRNSYS szoftver felhasználásával előállított fizikai alapú modellek szolgáltatják.

A keresett NN modell be- és kimeneti adatait a 9. ábra szemlélteti.



9. ábra Az NN modell be- és kimeneti adatai

ahol  $I(t)$  a sugárzás,  $T_{wc}(t)$  a környezet hőmérséklete,  $\dot{m}_L(t)$  a fogyasztás és  $\dot{m}_c(t)$  a kollektorkör tömegárama és  $T1(t), \dots, T8(t)$  a réteghőmérsékletek átlagos értékei a  $t$ -dik órában,  $T1(t-1), \dots, T8(t-1)$  pedig a rétegek hőmérsékletei az előző,  $t-1$ -dik órában.

A különböző struktúrák közül jó közelítést adott az a 2 rétegű hálózat, mely rejtett rétegében 8 db tangens-szigmoid és kimeneti rétegében 8 db lineáris átviteli függvényű neuront tartalmaz.

Mindkét rendszerre a paraméteridentifikációt elvégezve megállapítható, hogy a TRNSYS modell segítségével kapott réteghőmérsékletek, valamint mért sugárzás és tervezett fogyasztási adatok felhasználásával mindkét rendszer leírására alkalmas NN struktúrát dolgoztam ki, melynek segítségével a rétegek hőmérséklete jól becsülhető. A tanítások során az átlagos eltérések 0,8 °C míg a validálásnál 1,2 °C-on belül voltak.


### 3.4. Szoláris háztartási vízmelegítő rendszer NN modellje mért adatok alapján

A szoláris rendszerekre fizikai alapú modell adatainak felhasználásával kidolgozott modellt a háztartási rendszerre mérési adatok alapján pontosítottam.

Az adatgyűjtő rendszer percenként rögzíti az adatokat. A mérések 2006. júl. 5. és dec. 22. között zajlottak.

Óránkénti átlagos adatok esetén az átlagos eltérés a mért és a modell által generált adatok között a tanítás során 0,53 °C. A 10. ábra a tanulóhalmaz egy részére mutatja a mért ( $T_i$ ) és NN generált ( $NN_i$ ) adatokat, a jobb áttekinthetőség miatt csak az 1. (felső), 3., 6. és 8. (alsó) rétegekre vonatkozóan.

### 3. Eredmények



10. ábra Mért és NN generált réteghőmérsékletek (2006. aug. 7-10.)

A modell helyességének ellenőrzésére 185, a tanítás során fel nem használt adatsort alkalmazva az átlagos eltérés 0,76 °C volt.

Az NN eredményének elemzésekor megfigyelhető, hogy az NN azokra a szakaszokra mikor nincs fogyasztás sokkal pontosabb közelítést ad. A fogyasztások környezetében pedig az alsó rétegeknél a legszembetűnőbb az eltérés a mért és NN segítségével becsült értékek között. Ezek miérettjé kutatva az óránkéntinél rövidebb időlépés alkalmazásának irányába indultam.

Az időlépés NN modell eredményére vonatkozó hatásának vizsgálatához és az optimális időlépés meghatározásához 30, 10, 5, 2 és 1 perces átlagos adatokra is elvégeztem a modellezést. Ugyanazt az NN struktúrát, tanuló algoritmust és mérési adatsort használtam mind a tanításnál mind a validálásnál, mint az óránkénti átlagértékek számítása során.

A 2. táblázat foglalja össze a különböző időlépések esetén kapott számszerű eredményeket.

2. táblázat A különböző időlépésű modellek jellemző adatai

Időlépés [min]	Tanulóhalmaz mérete [adatsor]	Tanítás eredménye [°C]	Validálás eredménye [°C]	Tanulásnál 1000 tanulási ciklus futási ideje* [s]
60	2526	0,53	0,76	988
30	5084	0,46	0,63	1935
10	15215	0,29	0,39	5902
5	30934	0,22	0,26	12043
2	77180	0,13	0,14	34006
1	153859	0,07	0,08	584032

A tanításnál és a validálásnál kapott  $d_{\text{tan}}(t)$  ill.  $d_{\text{val}}(t)$  átlagos eltérések jól közelíthetők


a tanításnál 
$$d_{\text{tan}}(t) = a_1 \left(1 - e^{-\frac{t}{b_1}}\right),$$

a validálásnál 
$$d_{\text{val}}(t) = a_2 \left(1 - e^{-\frac{t}{b_2}}\right)$$



### 3. Eredmények


függvényekkel. Meghatároztam a függvények paramétereit és a korrelációs együtthatókat. Az adatpontokat és az illesztő görbéket a 11. ábra mutatja.



11. ábra Tanítás és validálás eredményének időlépéstől való függése

Figyelembe véve az adatgyűjtések gyakoriságát, az igényelt pontosságot, a meteorológiai adatokban bekövetkező változások gyorsaságát a rendszer alkotók és a mérő-érzékelő rendszer tehetetlenségi idejét: az optimális időlépés 5 min.

Megvizsgálva a réteghőmérsékletkülönbségét NN modell és a mért réteghőmérsékletkülönbségek között (12. ábra,  $d_i$  az  $i$ -edik réteg mért és NN által becült hőmérsékletkülönbsége,  $fogy$  pedig a fogyasztás) kapjuk, a nagy eltérések a vízkivételek környezetében találhatók.



12. ábra Mért és NN generált réteghőmérsékletkülönbségei és az alkalmankénti vízfogyasztás (2006. aug. 1-7.)


A fogyasztásmentes szakaszt a kidolgozott modell jó közelítéssel leírja. A kritikus vízkivételi szakaszokra azonban a pontosság érdekében új NN modell kidolgozása szükséges.

Az 5 percenkénti mérési adatsorból kiválasztottam a fogyasztás környezetébe eső szakaszokat (a fogyasztást megelőző 2. ill. azt követő 7. időintervallum közötti szakaszok mérési adatai). Ezek egymás után fűzésével keletkezett alaphalmazból a 2070 adatsort (207 vízkivétel) a tanításhoz. 200 adatsort, (20 vízkivétel, az adatok  $\approx 10\%$ -a) a validáláshoz különítettem el. Ezen szakaszokra az alap NN modell  $0,76^\circ\text{C}$  átlagos eltérést adott.

### 3. Eredmények

A vízkivételeket legjobb közelítéssel leíró NN a rejtett rétegében 19 tangens-szigmoid a kimeneti rétegében pedig 8 lineáris átmeneti függvényű neuront tartalmaz. Az átlagos eltérés a mért és NN segítségével becsült réteghőmérsékletek között a tanítás során 0,54 °C.

A 13. ábra a validálás eredményét mutatja egymás után fűzött vízkivételi szakaszokra.




13. ábra A validálás eredménye 8 egymás után fűzött vízkivételi szakaszra

A validálás során 0,57 °C átlagos eltérés adódott, ami közel 0,2 °C-kal (25%) pontosabb, mint az alapmodell alkalmazása esetén kapott érték.

Tehát a napenergiás rendszer melegvíz tárolójában kialakuló hőmérsékleti viszonyok 1 dimenzióban, 8 egyenlő vastagságú réteg középpontjában 2 különböző NN modell segítségével írhatók le. Ezen ún. kibővített modell lényege, hogy a fogyasztásmentes szakaszokban a réteghőmérsékleteket az alap NN modell ( $NN_1$ ), míg a vízkivételek környezetében a fogyasztási szakaszra kidolgozott NN modell ( $NN_2$ ) írja le. (14. ábra)

$$NN(t) = \begin{cases} NN_1(t), & \text{normál működés esetén} \\ NN_2(t), & \text{vízkivételi szakaszokon} \end{cases}$$



14. ábra A kibővített NN modell

A modell érvényességi határainak vizsgálatára 2007. márc. 28-tól tesztelési céllal méréseket végeztem. Ezen mérési adatokból - az optimális időintervallumnak megfelelően - 5 percenkénti átlagértékek esetén vizsgáltam az NN által becsült és a mért értékek alapján adódó értékeket.

- Az első vizsgálatban azt néztem meg, hogy amennyiben a márc., ápr. és május hónapokban 1-1 nap bemenő adatai a tanult tartományba esnek (meteorológiai adatok, max 60 l óránkénti vízkivétel), akkor milyen eredményt ad a kibővített modell. A várakozásnak megfelelően, a modell a tesztelés során a validálásnál kapott tartományon belüli értéket adott.

A feltételek közül a kiinduló réteghőmérséklet a vízfogyasztás mennyisége és időbeli eloszlása voltak azok a tényezők, melyek változtatására lehetőségem volt.

- A második vizsgálat során azt néztem meg, hogy hogyan reagál a kibővített modell a tanulás során megtanított 60 l-nél nagyobb fogyasztásra különböző feltételek esetén.

A vízkivételek mennyiségére érzékeny a modell, a tanított értéket meghaladva (alkalmanként 70, 80, 90 és 100 l víz fogyasztása során) az eltérések megnövekednek. Ez a turbulens folyamatok a tároló nagyobb részére való kiterjedésére utal, amit a tároló esetünkbeli kis mérete fokoz. A jelenséget fizikai alapú modellek is csak közelítően tudják kezelni.

A jelenség leírására jó alternatívát jelenthet az NN, ha mérési adatok alapján megtanítjuk minél több ilyen viselkedésre is.

A vizsgálatokat elvégeztem 30 °C alatti és feletti kiinduló átlagos réteghőmérsékletek esetén, ez nem jelentett különbséget a becslés pontosságában.

Vizsgáltam szivattyú működése közbeni és anélküli fogyasztás esetét. Itt nagyobb eltérés adódott a kora reggeli ill. késő esti vízkivételek esetén, mint a napközbeninél, ami azzal magyarázható, hogy a tanítás során lényegesen több napközbeni minta szerepelt, és ezt a tanított fogyasztáson túl is pontosabban tudta kezelni a modell.

Vizsgáltam, hogy valós fogyasztás esetén a validált modell milyen eredményt ad.

A melegvíz fogyasztások zuhanyozáskor, kézmosáskor a fürdőszobában, illetve főzéskor, mosogatáskor a konyhában történnek.

Mivel a rendszer mérete kb. 2 fő melegvízszükségletének biztosítására elegendő, így 2 főre mértem a napi fogyasztáseloszlást átlagos hétközbeni és hétvégi napra és e szerint végeztem a szimulációkat. A modell segítségével nyert eredmények reális réteghőmérséklet értékeket adtak.

## 4. ÚJ TUDOMÁNYOS EREDMÉNYEK

### 1. Meteorológiai adatok becslése NN segítségével

A szoláris rendszerek alkalmazhatóságának megítélésében a legfontosabb tényező az adott helyszín meteorológiai adottsága. Ennek megfelelően egy statikus és egy prediktív NN alapú modellt dolgoztam ki, amely adott földrajzi helyre vonatkozóan alkalmas a szoláris potenciál (napsugárzás, hőmérséklet) becslésére. Megállapítottam, hogy a prediktív modell pontosabb, a legjobb közelítést adó előrejelzést a megelőző 5 óra adatainak felhasználásával adja. Igazoltam, hogy ha külön prediktív modellt alkalmazunk a hőmérséklet és a sugárzás becslésére, az előrejelzés átlagos pontossága a hőmérséklet esetén 17%-ról 5%-ra javul, a sugárzás pedig 18% átlagos pontossággal jelezhető előre.

### 2. Síkkollektor NN modellje

Kidolgoztam egy, a síkkollektor termikus viselkedését leíró neurális hálós alapú modellt. Meghatároztam a modell paramétereit és kimutattam, hogy a neurális hálós modell a tanítás során használt hőmérséklet és sugárzás tartományban állandó tömegáramok esetén 1 °C pontosságú közelítést ad a kollektorból kilépő szolárfolyadék hőmérsékletének becslésére. A síkkollektorok alaptípusaira elvégzett validálás alapján megállapítottam, hogy a megadott NN struktúra konstans tömegáramok esetén általánosan is alkalmazható síkkollektorok termikus viselkedésének modellezésére. Mérésekre alapozva a modellt a kollektor változó tömegáramú szakaszaira is kiterjesztve módosítottam. A javasolt NN struktúra segítségével 1,6 °C átlagos eltéréssel becsülhető bármely szakaszra a kollektorból kilépő szolárfolyadék hőmérséklete.

### 3. Speciális belső hőcserélő kialakítása és mérőrendszer kiépítése

Energetikailag a termikusan rétegzett tároló jobb hatásfokú, mint a kevert típusú. Ennek minél pontosabb megvalósítása érdekében - speciális hőcserélő beépítésével - a termikus rétegződés kialakulását és fennmaradását segítő módszert adtam meg. Mérési elvet dolgoztam ki és valósítottam meg a tároló magassága mentén 8 egyenlő vastagságú réteg középpontjaiban, amelyhez a vízmentes beépíthetőség és a hőtehetlenség szempontjából optimalizáltam az érzékelőfej méretét.

### 4. Tároló termikus rétegződését leíró alap NN modell

Általános NN struktúrát dolgoztam ki termikusan rétegzettnek tekinthető napenergiás tárolók réteghőmérsékleteinek becslésére. Meghatároztam a modell paramétereit egy háztartási és egy közepes méretű rendszerre. Igazoltam, hogy óránkénti átlagos adatok esetén a rejtett rétegében 8 tangens-szigmoid, a kimeneti rétegében 8 lineáris átviteli függvényű neuront tartalmazó NN segítségével átlagosan 1,2 °C pontossággal lehet becslést adni a rétegek következő órára várható hőmérsékletére.

#### 4. Új tudományos eredmények

---

##### 5. Időlépés hatása az NN tanítás és validálás pontosságára

A rendelkezésre álló mérési adatokból összefüggéseket határoztam meg a tároló termikus rétegződését leíró NN modell a tanítás és validálás során kapott  $d_{tan}(t)$  ill.  $d_{val}(t)$  átlagos eltérései és a  $t$  időlépés között, amelyek

a tanításnál 
$$d_{tan}(t) = a_1(1 - e^{-\frac{t}{b_1}}),$$

a validálásnál 
$$d_{val}(t) = a_2(1 - e^{-\frac{t}{b_2}})$$
 függvénnyel közelíthetők.

Identifikáltam a függvények paramétereit:  $a_1=0,5075$  °C,  $b_1=9,9944$  min,  $a_2=0,7385$  °C,  $b_2=12,7437$  min, és meghatároztam a korrelációs együtthatókat:  $R_{tan}= 0,991$  ill.  $R_{val}= 0,996$ . Az összefüggések alkalmasak arra, hogy 1 és 60 perc közötti tetszőleges időtartam esetén megadják a tanítás és validálás várható átlagos eltéréseit. Megállapítottam, hogy a mérési adatokból az 5 perces átlagos adatokkal történő becslés az optimális, figyelembe véve az adatgyűjtés gyakoriságát, az igényelt pontosságot, a meteorológiai adatok változásának gyorsaságát és a rendszer alkotók ill. a mérő-érzékelő rendszer tehetetlenségi idejét.

##### 6. NN modell a vízkivételi szakaszok leírásához

A mérési adatok elemzése alapján bizonyítottam, hogy a vízkivételek környezetében más jellegű a rendszer termikus viselkedése, mint a többi szakaszon. Így ezen szakaszok hatékonyabb modellezéséhez más NN-re van szükség. Kidolgoztam a vízkivételi szakaszok leírására alkalmas NN modellt, amely az alap NN modelltől a rejtett rétegbeli neuronok számában különbözik és meghatároztam a modell paramétereit egy háztartási méretű tárolóra. A vízkivételi szakaszokon a javasolt modell segítségével a réteghőmérsékletek becslésének pontossága 25%-kal javult. A szoláris vízmelegítő rendszer tárolójának 8 egyenlő vastagságú rétegében mérhető hőmérséklet becslésére javasolt kibővített modellt a 14. ábra részletezi.

##### 7. Fototermikus rendszer maximális napi energiabehozatalának meghatározása

Módszert adtam szoláris vízmelegítő rendszer kollektora maximális napi fajlagos energiabehozatalának becslésére. Megállapítottam, hogy a rendszerből fogyasztással kivett energia növelésével csak egy bizonyos határig növelhető a kollektor napi fajlagos energiabehozatala. Ezen a határon túl optimális sugárzási viszony, tárolóbeli kezdőhőmérséklet és fogyasztáseloszlás esetén sem növelhető tovább. A telítődés jellegű kapcsolatból meghatározható a kollektor maximális napi fajlagos energiabehozatala és az ehhez ideális napi fajlagos energiafogyasztás, ezen utóbbi értéket síkkollektor esetére  $2,1 \text{ kWh/m}^2$ -re identifikáltam.

## 5. KÖVETKEZTETÉSEK ÉS JAVASLATOK

Az NN modellezési módszer alkalmas szoláris vízmelegítő rendszerek vizsgált termikus viselkedéseinek tanult minták alapján történő leírásához. A problémákat leíró NN-ek viszonylag egyszerűek, a több rejtett rétegű NN-ek alkalmazása egyik esetben sem hozott jobb becslést.

Eltérő jellegű viselkedések leírására célszerű a viselkedési jellegekhez külön-külön NN-t kidolgozni. Ezzel a jelenség becslésének pontossága javítható.

A kidolgozott NN modellek a szimulációs részét alkotják egy neuro-fuzzy szabályozásnak.

Feltétlenül szükséges további mérési adatok gyűjtése, hogy egész évre vonatkozólag lehessen a kapott eredmények érvényességét kiterjeszteni.

Mivel a vízkivétel a vizsgálatok során limitált volt (max. 60 l óránként) mérési adatokat gyűjtök annak vizsgálatára, hogy sok nagyobb vízkivételi minta megtanulására is alkalmas-e a vízkivételi szakaszokra kidolgozott NN modell, vagy nagyobb vízkivételek esetén már más struktúrájú NN szükséges a viselkedés leírásához.

A vízfogyasztások nagyjából óránként és főként napközben történtek. Méréseket végzek sűrűbb vízkivétel, illetve a háztartási fogyasztásnak megfelelő, túlnyomó részben kora reggeli és késő esti fogyasztások esetén kialakuló réteghőmérsékletek vizsgálatához.

Tervezem annak a vizsgálatát, hogy a tárolóbeli turbulens folyamatokat mennyire képes megtanulni egy NN. Mivel sok mérőhely kialakítása megzavarná a rendszer belsejében kialakuló viszonyokat, lehetne először fizikai alapú modell közelítő eredményeivel próbálkozni a tanításnál.

A vizsgált síkkollektoros rendszer átalakításával lehetőség lesz a kollektorkör tömegáramának finomabb szabályozására - és egy áramlásmérő beépítésével ezen értékek rögzítésére -, ami az energiabehozatalt hatékonyabbá teszi.

A mérési adatok feldolgozása során derült ki, hogy célszerű lenne bővíteni a hőmérséklet mérési lehetőségeket.

Belső szoláris kör működtetésével a szivattyú ki-bekapcsolása következtében a szolárfolyadék hőmérsékletében bekövetkező tranziens viselkedés hatása a tároló oldalán nem jelentkezne (a szivattyú beindulásakor rövid ideig a tároló alsó rétegeiben hőmérséklet csökkenés), így növelhető lenne a rendszer hatékonysága.

A tárolót a kollektorral összekötő vezetékszakasza igen hosszú (2x21 m), és az épületen belül egy része nem szigetelt. Ennek a szigetelésével csökkenthető a veszteségek.

A fent tervezett átalakítások nem túl költségesek, részben azért is nem valósultak meg eddig, mert az NN modellek kidolgozásához a rendszer változatlan állapota mellett volt szükség sok mérési adatra.

## 6. ÖSSZEFOGLALÁS

A műszaki gyakorlatban egyre fontosabb szerepet kap a megújuló energiák alkalmazása. Kutatómunkám célja hozzájárulni a síkkollektoros vízmelegítő rendszer termikus viselkedéséről rendelkezésre álló ismeretek kiegészítéséhez és a rendszerrel hasznosítható napenergia növeléséhez, eszközként neurális hálós modellezést alkalmazva.

A szoláris rendszerek alkalmazhatósága szempontjából elengedhetetlenül fontos meteorológiai adatok előrejelzésére kidolgoztam egy statikus és egy prediktív NN alapú modellt. A modellek alkalmasak adott helyszínen a sugárzás és hőmérséklet várható értékének becslésére adott nap adott órájára illetve a megelőző 5 óra adatai alapján a következő órára.

A szoláris rendszer síkkollektora termikus viselkedésének leírására készített NN modell segítségével a kollektorból kilépő szolárfolyadék hőmérséklete becsülhető meg a sugárzás, a kollektor környezetének hőmérséklete, a kollektorköri tömegáram és a kollektorba belépő szolárfolyadék hőmérsékletének adataiból.

Elkészítettem háztartási és közepes méretű szoláris vízmelegítő rendszer tárolói termikus rétegződésének becslésére alkalmas fizikai alapú modelleket a TRANSYS szoftver segítségével. Ezen fizikai alapú modellek adatait felhasználva határoztam meg a tárolók termikus rétegződésének leírására alkalmas NN alapú modellt.

A szoláris vízmelegítő-rendszer tárolója energia tárolás szempontjából kedvező termikus rétegződésének elősegítése és fennmaradása érdekében speciális hőcserélőt építettem a vizsgálataim középpontjában lévő háztartási méretű rendszer tárolójába, és kialakítottam 8 egyenlő vastagságú rétegének középpontjaiban a termoelemes hőmérsékletmérés lehetőségét.

A 2006-ban gyűjtött mérési adatok feldolgozásával, elemzésével meghatároztam a tanulmányozott rendszer fontosabb paramétereit, és összefüggéseket adtam meg a fogyasztás és a rendszerrel gyűjtött energia kapcsolatára.

A mérési adatokra alapozva finomítottam a tárolóbeli termikus rétegződés leírására a fizikai alapú modell alapján készített NN modellt. Bebizonyosodott, hogy a vízkivételi szakaszok pontosabb leírásához ezen szakaszokra egy másik, a rejtett rétegében több neuront tartalmazó NN alkalmazására van szükség. Meghatároztam a vizsgált rendszerre a modell paramétereit, vizsgáltam az érvényességi határokat és szimulációkat végeztem valós fogyasztások esetére.

A munkám során kidolgozott NN modellek a tanításnál alkalmazott tartományokban megbízható eredményeket adnak. A modellek felhasználhatók szimulációkhoz és a segítségükkel nyert tapasztalatok hasznos információkat jelentenek a rendszerek tervezésénél, méretezésénél és minél hatékonyabb üzemeltetésénél.

## 7. SZAKMAI PUBLIKÁCIÓK JEGYZÉKE

### Lektorált cikk idegen nyelven

1. Farkas I., **Géczy-Víg P.** (2003): Neural network modelling of flat-plate solar collectors, *Computers and Electronics in Agriculture*, Vol. 40, No. 1-3, 2003, p. 87-102.

#### Hivatkozás

- Sozen A., Arcaklioglu E., Ozalp M. (2004): Estimation of solar potential in Turkey by artificial neural network. *Energy Conversion and Management*, 45 (18-19) 3033-3052.
2. **Géczy-Víg P.**, Farkas I. (2006): Modelling of heat storage of solar thermal system with neural network, *Hungarian Agricultural Engineering*, 19/2006, p. 71-73.

### Nemzetközi konferencia kiadvány

1. Farkas I., **Géczy-Víg P.** and Tóth M. (2001): Neural network modelling of solar collectors, Preprints of the IFAC/CIGR Fourth International Workshop on Artificial Intelligence in Agriculture (AIA 2001), Budapest, Hungary, June 6-8, 2001, p. 55-60.
2. **Géczy-Víg P.**, Farkas I. (2004): Experiences with a small case stand-alone photovoltaic energy system Solar&Wind International Conference and Workshop, SWIC 2004, ICPE–Agigea Test Facility Site, Bucarest, Romania, August 23-27, 2004, p. 8.
3. **Géczy-Víg P.**, Farkas I. (2004): Sizing of a stand-alone photovoltaic energy system, CD-ROM Proceedings, AgEng 2004 Conference, Engineering the Future, Leuven, Belgium, September 12-16, 2004. p. 8.
4. **Géczy-Víg P.**, Farkas I. (2006): Modelling of thermal stratification in a solar storage tank, CD-ROM Proceedings, EuroSun 2006, Glasgow, UK, 2006, pp.
5. **Géczy-Víg P.**, Farkas I. (2007): Energy analysis of a solar water heating system, NorthSun 2007. The 11th International Conference on Solar Energy in High Latitudes May 30 - June 1, 2007 Riga, Latvia
6. **Géczy-Víg P.**, Farkas I. (2007): Possibilities of ANN modelling for thermal behaviour of a solar system, June 5-6, 2007 Nitra, Slovakia
7. **Géczy-Víg P.**, Farkas I. (2007): Neural network modelling of solar thermal system, SSSEA 2007, First National Summer School Solar Energy Applications, August 20-25, 2007 Agigea, Romania
8. **Géczy-Víg P.**, Farkas I. (2007): Energy production of a solar system in connection with water consumption, HHT 2007, Home High Tech – 2007, August 27-28, 2007, Agigea, Romania
9. **Géczy-Víg P.**, Farkas I. (2007): Different models for determination of thermal stratification in a solar storage tank, SWC2007, ISES Solar World Congress, September 16-21, 2007 Beijing, China

### Magyar nyelvű konferencia kiadvány

1. **Géczy V. P.**, Farkas I. (2002): Napkollektorok modellezése neurális hálóval, MTA Agrár-Műszaki Bizottság, XXVI. Kutatási és Fejlesztési Tanácskozás, Gödöllő, 2002. jan. 15-16, 2. kötet 201-205. o.



2. **Géczy V. P.,** Farkas I. (2003): Neurális háló alkalmazása szoláris potenciál meghatározására, MTA Agrár-Műszaki Bizottság, XXVII. Kutatási és Fejlesztési Tanácskozás, Gödöllő, 2003. jan. 21-22, 3-kötet 172-176. o.
3. **Géczy V. P.,** Farkas I. (2004): Fotovillamos (PV) energiatermelő rendszerek méretezése, MTA Agrár-Műszaki Bizottság, XXVIII. Kutatási és Fejlesztési Tanácskozás, Gödöllő, 2004. jan. 20-21, 4. kötet, 341-345. o.
4. **Géczy V. P.,** Farkas I. (2005): Napenergiás hőtároló hőmérséklet-eloszlásának vizsgálata neurális hálóval, MTA Agrár-Műszaki Bizottság, XXIX. Kutatási és Fejlesztési Tanácskozás, Gödöllő, 2005. jan. 18-19, 3. kötet 94-98. o.
5. **Géczy V. P.,** Farkas I. (2006): Napkollektoros rendszer hőtárolásának modellezése neurális hálóval, MTA Agrár-Műszaki Bizottság, XXX. Kutatási és Fejlesztési Tanácskozás, Gödöllő, 2006. jan. 24. 3. kötet 111-115. o.
6. **Géczy V. P.,** Farkas I. (2007): Víz tároló rétegződésének meghatározása neurális hálóval, MTA Agrár-Műszaki Bizottság, XXXI. Kutatási és Fejlesztési Tanácskozás, Gödöllő, 2007. jan. 23.

### Nemzetközi konferencia absztrakt

1. **Géczy-Víg P.,** Farkas,I. (2001): Neural network as a tool for modelling of solar collectors, 7th Workshop on Energy and Environment, Gödöllő, Hungary, November 5-6, 2001, p. 14.
2. **Géczy-Víg P.,** Farkas I. (2002): Neural network as a tool for modelling of solar system, 8<sup>th</sup> Workshop on Energy and Environment, Gödöllő, Hungary, November 4-5, 2002, p. 22.
3. **Géczy-Víg P.,** Farkas I (2003): Wind speed modelling, 9<sup>th</sup> Workshop on Energy and Environment, Gödöllő, Hungary, November 3-4, 2003, p. 17.
4. **Géczy-Víg P.,** Farkas I (2004): Neural network modelling of solar water heating system, 10<sup>th</sup> Workshop on Energy and Environment, Gödöllő, Hungary, November 8-9, 2004, p. 24.
5. **Géczy-Víg P.,** Farkas I. (2005): Study of thermal stratification in a medium size solar storage tank, 11<sup>th</sup> Workshop on Energy and Environment, Gödöllő, Hungary, November 7-8, 2005, p. 12.
6. **Géczy-Víg P.,** Farkas I. (2006): Use of different neural network models for determination of solar radiation and temperature, 12th Workshop on Energy and Environment, Gödöllő, Hungary, September 18-19, 2006, p. 12.

### Kutatási jelentés

1. Farkas I., **Géczy-Víg P.,** Papadakis,G. and Mohamed,E. (2002): Determination of solar energy availability by artificial neural network (ANN), Research Report, Department of Physics and Process Control, Szent István University Gödöllő, No 29, November 2002