



A Balaton vízlengésének becslése mesterséges neurális háló alkalmazásával

Tudományos Diákköri konferencia 2012

Készítette

Jakab Jenő

*Budapesti Műszaki és Gazdaságtudományi Egyetem
Építőmérnöki kar, Infrastruktúra - Építőmérők mesterszak
Víz-és vízi környezetmérnöki szakirány
II. évfolyam*

Konzulens

Dr. Krámer Tamás

*Egyetemi docens
Budapesti Műszaki és Gazdaságtudományi Egyetem
Építőmérnöki kar
Vízépítési és Vízgazdálkodási Tanszék*

2012. október

Köszönetnyilvánítás

Ez úton szeretném megköszönni mindazoknak a segítségét, akik e dolgozat létrejöttéhez hozzájárultak! Külön köszönöm konzulensemnek: Krámer Tamásnak, akitől sok hasznos konzultációs lehetőséget, fontos szakmai észrevételeket, iránymutatást, segítőkész, türelmes hozzáállást kaptam mindvégig. Köszönöm még családomnak és barátnőmnek, akitől megkaptam a dolgozat megírásához szükséges feltételeket és biztatást.

Tartalomjegyzék

Köszönetnyilvánítás.....	- 1 -
Tartalomjegyzék.....	- 2 -
Ábra és táblázat jegyzék.....	- 3 -
1. Bevezetés	- 5 -
2. Rendelkezésre álló adatok.....	- 6 -
3. Neurális hálók ismertetése.....	- 8 -
3.1. Természetes neurális hálók, az idegrendszer működésének elve.....	- 8 -
3.2. Mesterséges neurális háló modellje	- 9 -
3.3. A hálózat súlyainak optimalizálása a backpropagation eljárás.....	- 13 -
4. Alkalmazott szoftver.....	- 16 -
5. A Medence modell szükségességének tárgyalása.....	- 17 -
6. Medence 1D alapfeladat	- 18 -
6.1. Egyszerűsítő feltevések definiálása	- 18 -
6.2. Neurális háló 1 órás előrejelzésre	- 21 -
6.2.1. Megfelelő hosszúságú idősorok kijelölése	- 21 -
6.2.2. Neurális háló megépítése referencia esetre	- 26 -
6.2.3. Az ANN paraméterezése és érzékenységvizsgálat.....	- 28 -
7. Medence 2D alapfeladat valós szél esetén	- 36 -
7.1. Egyszerűsítő feltevések definiálása és a megfelelő hosszúságú idősorok kijelölése..	- 36 -
7.2. Egy órás előrejelzés készítése redukált csomópontú neurális hálón.....	- 42 -
7.3. Hét órás előrejelzés készítése a redukált csomópontú neurális hálón	- 47 -
8. Hétórás vízszint-előrejelzés készítése a Balatonra Siófoknál	- 60 -
9. Összefoglaló	- 72 -
10. Hivatkozások.....	- 74 -

Ábra és táblázat jegyzék

1. ábra biológiai idegsejt szerkezeti hatásmechanizmusa	- 8 -
2. ábra jeláthaladás az i-edik neuronon.....	- 10 -
3. ábra A TDK munkámban alkalmazott QNet szoftverben választható jel transzformációs függvények (természetesen a vázolt összefüggések a különböző paraméterekkel torzított (nyújtás-zsugorít, eltolás) függvényvariánsokra is igazak).	- 11 -
4. ábra Cybenko – Hornik – Funahashi tétel grafikus megjelenítése és értelmezése egy két rétegű ANN szerkezeten	- 12 -
5. ábra A számítási rácsháló a Tecplot (megjelenítést teszi lehetővé) programban x=keleti koordináta, y= északi koordináta m -egységben	- 18 -
1. táblázat Lekérdezési pontok a medencében.....	- 20 -
8. ábra Az 1. pont vízszint idősora, mint a medence válasza a fent definiált 1D keleti szélre	- 24 -
11. ábra ANN hálózat vázlata az 1D Medence feladatnál, 1 órás előrejelzésnél	- 26 -
2. táblázat Főbb futtatási és modell paraméterek a 1D Medence feladatnál 1 órás előrejelzésnél (szürke szín jelöli a REFERENCIA01 modellhez képest megváltoztatott paramétert).....	- 29 -
3. táblázat Különböző előrejelzések hibáinak statisztikai mutatószámai az 1D Medence feladatnál (a legkedvezőbb értékek zöld színnel)	- 31 -
15. ábra Rejtett csomópontok részesevése az előrejelzett vízszintekben 1D Medence feladatnál a különböző paraméterekkel ellátott ANN futtatások estén.....	- 35 -
16. ábra Szélsőbesség idősorok keletre, illetve északra mutató komponensekkel Siófokon (BIR) 2009.06.06 – 2009.09.06 között.....	- 39 -
4. táblázat Főbb futtatási és modell paraméterek a 2D Medence feladatnál 1 órás előrejelzésnél (szürke szín jelöli a referencia modellhez képest megváltoztatott paramétert).....	- 43 -

22. ábra Tanuló halmaz RMS hibafüggvénye az iterációs lépések függvényében REDREFERENCIA01 futtatásnál.....	- 43 -
23. ábra REDREFERENCIA01 futtatás előrejelzett értékeinek és a célértékeknek a viszonya.....	- 44 -
5. táblázat 1 órás előrejelzések hibastatisztikája 2D Medence feladatnál (a legkedvezőbb értékek zöld színnel)	- 45 -
26. ábra Bemenő csomópontok részesevé az 1. pontba előrejelzett vízszintekben 2D Medence feladatnál a különböző paraméterekkel ellátott ANN futtatásoknál	- 47 -
6. táblázat Főbb futtatási és modell paraméterek a 2D Medence feladatnál 7 órás előrejelzésnél (szürke szín jelöli a referencia modellhez képest megváltoztatott paramétert)	- 49 -
27. ábra REFERENCIA (felső) és STRUKTREFERENCIA (alsó) hálózati modellek a QNetbe 7 órás előrejelzéshez.....	- 50 -
7. táblázat A 7 órás előrejelzés hibastatisztikája 2D Medence feladatnál (a legkedvezőbb értékek zöld színnel)	- 55 -
35. ábra A hiba szórásának változása az előrejelzés időbeli előrehaladtával a különböző ANN változatoknál	- 56 -
45. ábra SIÓFOK jelű hálózati modell a QNetben 7 órás előrejelzésnél.....	- 63 -
8. táblázat Főbb futtatási és modell paraméterek a Siófoki t=0...6 órás vízállás- előrejelzésnél.....	- 64 -
9. táblázat SIÓFOK modell hibastatisztikája 7 órás előrejelzésnél.....	- 66 -
9. Összefoglaló	- 72 -

1. Bevezetés

TDK dolgozatomban a mesterséges neurális hálók (artificial neural network, röviden: ANN) alkalmazhatóságát vizsgálom a hidraulikában, hidrológiában egy speciális feladat: a Balaton vízlevegéseinek előrejelzésére. Az adatvezérelt eljárások előnyét kihasználva olyan optimalizált számítási struktúra megalkotására teszek kísérletet, ami a fizikai alapú hidrodinamikai modelleknél kisebb erőforrásigénnyel (gyorsabban), azok pontosságának nagyságrendjébe eső megoldást, előrejelző vízszintbecslést céloz meg Siófoknál 7 órás időtávra. A modellalkotás során élek azzal a feltételezéssel, hogy a Balaton sekély tó, amely vízmozgásaiért döntően a szél a felelős (a vízgyűjtő-lefolyás, a légnyomás, a vízhőmérséklet-különbségek és a hajózás hatásait tehát elhanyagolhatónak ill. lokálisnak veszem). A jövőben kialakuló vízszinteket ezért csak a múltbeli vízszintek és a jövőbeli és közelmúltbeli szélsőségek alakítják, ahol a múltbeli vízszintek egyfajta tehetetlenséget, az egyensúlyiból kilendült kezdeti állapotot (a múltbeli szelek hatásainak akkumulációját) a jövőbeni szélsőségek egyfajta dinamikát, gerjesztést reprezentálnak. Tengeri vízszint előrejelzéshez, megelőző vízszint és egyidejű szélsőségek adatokat alkalmaztak már neurális hálóval történő feladatmegoldásnál (*Sztobryn, M. 2003*). Számításaimhoz hosszú adatsorokra volt szükségem, amihez a Balatoni Információs Rendszer (későbbiekben: BIR) 2009.06.06 – 2009.09.06 időintervallum diszkrét pontokban mért vízszint és szélsőségek adatait használtam fel, egyórás időközre átlagolva.

Mivel az ANN képességeit a munkám elején még nem ismertem és a szakirodalom is inkább ajánlásokat, irányelveket tartalmaz az ANN -nel történő feladatmegoldásoknál általánosan, ezért dolgozatomban másik célja a megoldáshoz vezető út, a tapasztalatok bemutatása is. Ezért a képességek feltárásához, az esetleges buktatók könnyebb azonosításához az eredeti feladatot leegyszerűsítettem egy medence alapfeladattá, amelyet fokozatosan bonyolítva jutok el az

eredi feladatig. Az alapfeladatot, illetve a bonyolítás lépcsőfokait, a kapott eredményeket, tapasztalatokat dolgozatomban fejezetekre bontva tárgyalom.

2. Rendelkezésre álló adatok

Mesterséges neurális hálóval nem fizikai alapegyenletek megoldásával jelezzük előre a vízszint változásait, hanem korábbi adatsorokon megtanult függvénykapcsolatok általánosításával. A bemeneti és a kimeneti változókból ehhez minél hosszabb adatsorról kell rendelkezünk, hogy a tanítás tényleg megismerhesse a rendszert és az igazolás tényleg letesztelhesse az általánosító képességet.

Munkám elvégzéséhez a Vízépítési és Vízgazdálkodási Tanszék jóvoltából rendelkezésemre állt a Balatoni Információs Rendszer (BIR) mérőhálózatával megmért vízszint és szélesség idősorok Siófoknál és Keszthelynél, valamint csak a szélesség idősorok Balatonszemesnél 2008.01.01 és 2010.08.14 között átlagosan 5 perc finomsággal. Magából a teljes idősorból a neurális háló tanításához és az ellenőrzéshez mindössze 3 hónap adatsorát használtam fel 2009.06.06 -2009.09.06 között, mivel a mérőrendszer gyakori meghibásodása miatt ebben az időszakban volt elég hosszú folytonos idősorom az összes adatsort tekintve (hidrodinamikai modellel történő összehasonlítás miatt fontos). Az alkalmazott időszak kiválasztásánál figyeltem az évszak jellegére is, mivel télen a jégképződés miatt a szél és vízállás közötti kapcsolat jelentősen megváltozik, gyengébb lesz. Nem csak műszaki szempont ez: a Balaton turisztikai jelentőségének megfelelően a pontos előrejelzéseknek éppen nyáron lehet a legnagyobb jelentőségük. A neurális háló gyakorlati alkalmazásánál figyelembe kell venni tehát, hogy nyári adatsorokon történt a tanítás-ellenőrzés és csupán csak egy évre vonatkozóan.

A rendelkezésre álló 5 perc finomságú adatsorokat az ANN tanításához és az igazolásához is órákra kiátlagoltam, tehát a vízszint előrejelzésem is csak órás átlagértékeket ad. Az átlagolás

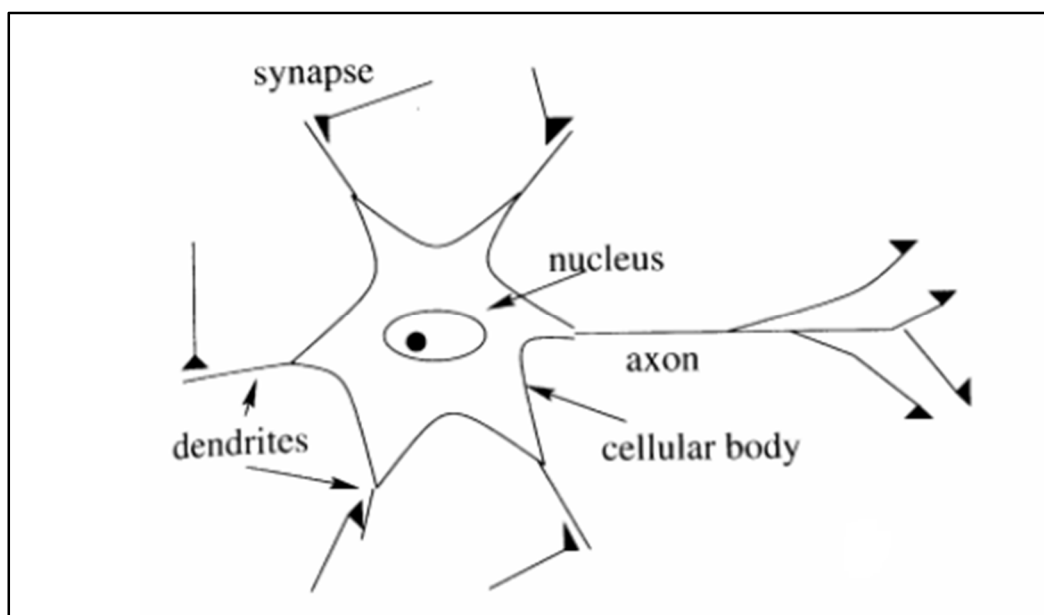
azért megengedhető, mert az előrejelzésem csupán a tólengésekre, a Balaton kis frekvenciájú hullámmozgására vonatkozik, amelynek a jellemző periódusideje meghaladja az egy órát, viszont az átlagolás révén kiküszöbölhető a tófelszín nagy frekvenciájú hullámozgása. A Balaton lengésideje a tó hossz tengelyében kicsit több, mint 7 órára tehető, tehát az órás felbontás ebből a szempontból megfelelő pontosságú. Keresztirányban (a tó szélesség/hosszúság arányának megfelelően) a lengésidő mintegy háromnegyed óra, tehát eleve tudható, hogy ez az órás időközű átlagos vízszintekkel nem képezhető le. Azonban a hosszirányú, és nem a keresztirányú hullámoktól várjuk a legnagyobb amplitúdókat, ezért a TDK munkámban ezekre a leghangsúlyosabb vízszintingadozásra kerestem gyors és pontos előrejelző módszert.

Az ANN „fekete doboz” (black-box) jellege miatt fontos megjegyezni, hogy az eljárás nem vizsgálja az adatok mértékegységét: a vízszintekre vonatkozó számítási csomópontjai cm-ben megadott Siófoki vízmércén (103,41 mBf) mért vízszintekre adnak helyes értéket, a szélesség pedig 10 m-es magasságban értelmezett, m/s mértékegységben, külön keleti és északi koordinátákra bontva (egy időpont szélesség-vektorára tehát két számítási csomópont vonatkozik az ANN-ben). A gyakorlati alkalmazásnál fontos hangsúlyoznom, hogy a BIR a partoktól távol, nyíltvízen 6 m-es magasságban mért adatokat teszi közzé, amely jelentősen más értékeket rögzít, mint például a szárazföldi (az OMSZ Siófoki állomása) rendszerek a víz és a szárazföld fölötti légköri határréteg közti változásból fakadóan. A BIR értékeket a logaritmikus függőleges szélprofilnak megfelelően az egyezményes 10 m-re transzformáltam, hogy egyöntetűvé tegyem az OMSZ parti méréseivel. A szélesség felvetítéséhez a hullámozgó vízfelszín aerodinamikai érdességmagasságát 0.5 mm –re vettem fel, amely egy átlagos irodalmi érték víz-levegő határrétegnél. Természetesen a hullámozgás változásával változik ez az érdesség, de ennek a hatását a víz-levegő határrétegre elhanyagolom.

3. Neurális hálók ismertetése

A munkámban a QNet szoftverben valósítottam meg a vízszint-előrejelző mesterséges neurális hálókat. Ebben a fejezetben először vázolom a biológiai idegrendszer tanulási folyamatát és ennek a számítási célú absztrakt analógiáját, a mesterséges neurális hálókat, végül ismertetem a QNet szoftver főbb szolgáltatásait.

3.1. Természetes neurális hálók, az idegrendszer működésének elve



1. ábra biológiai idegsejt szerkezeti hatásmechanizmusa

A mesterséges neurális hálók az emberi tanulás folyamatát modellezik az idegsejtek, neuronok működését alapul véve. Egy idegsejtnél a beérkező elektromos jelek a dendrites és synapses érzékelők segítségével jutnak el a sejtmagig, ahol a sejtmag a jelen transzformációt hajt végre. A transzformált jelet ezt követően a vizsgált sejt magja az axonon keresztül továbbítja a kapcsolódó szomszédos neuronokhoz. Két neuron közti kapcsolat erőssége a tanulási folyamat során megváltozhat. Tehát az idegsejtbe egy másik idegsejtből érkező jel erőssége megváltozhat, illetve a több kapcsolódó neuron esetén a jelösszegben szereplő arány

is módosulhat. A változás hatása pedig továbbterjedve, rengeteg neuron-neuron közti kapcsolatot változtathat meg. Hogy legyen fogalmunk, hogy milyen mennyiségekről, komplexitásról van szó vegyük az emberi agy szürkeállományát, melynek térfogata 0.32 dm^3 átlagosan. Ebben a térfogatban kb. 16×10^9 neuron található, melyek közül több millió áll egymással közvetlen kapcsolatban. (Paláncz 2011)

Egy példán illusztrálva képzeljünk el egy kisgyermeket, aki első ízben fog a kezében vörösen izzó, felhevített fémdarabot. Korábbi tapasztalatok híján, játékszernek nézve a testet, gyanútlanul megfogva azt éles fájdalomérzetet tapasztal. Egy következő alkalommal, hasonló helyzetben látva a fém vörös színét már nem nyúl a fém után. Ebben az esetben a bejövő inger a vörösen izzó fém érzékelése, felismerése, kimenő jel pedig a viselkedés, a fém megfogása, illetve nem megfogása. A tanulás folyamata leegyszerűsítve és rengeteg hatást elhanyagolva tekinthető úgy, mint a gyermek idegrendszerében az idegsejtek közötti kapcsolat megváltozása.

3.2. Mesterséges neurális háló modellje

A mesterséges neurális háló modell az idegrendszer absztrakciójával állítható elő, ahol az idegsejtek magjai tekinthetők egy gráf szerkezet csomópontjainak, a synapsesek és axonok pedig súlyozott éleknek. Az idegsejtbe beérkező jelek tehát az alábbi összegképlettel fejezhetők ki:

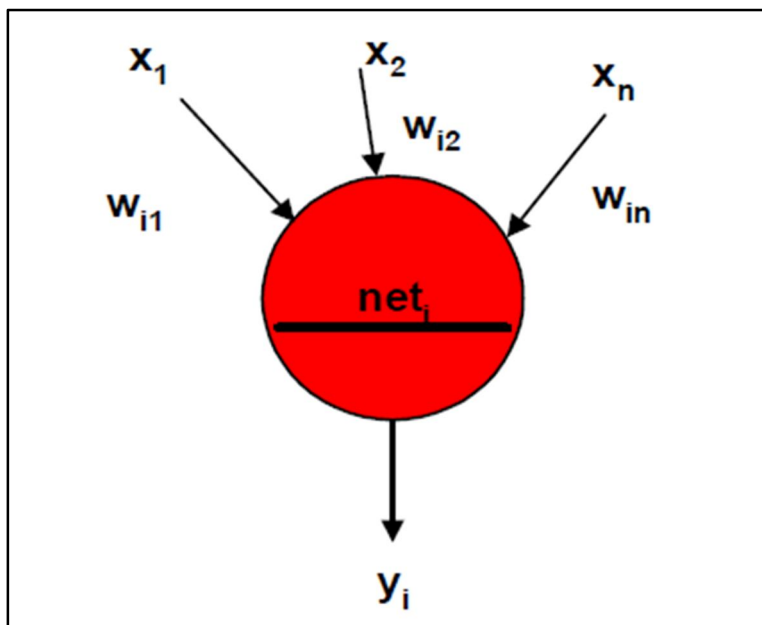
$$net_i = \sum_{j=1}^n w_{i,j} \cdot x_j$$

ahol,

- **i**: A vizsgált neuron sorszáma

- **j**: Az **i**-edik vizsgált neuronhoz kapcsolódó neuronok az előző rétegből

- net_i : A bejövő jelek súlyozott összege az i -dik neuronon
- x_j : Bejövő jel erőssége a j -dik neuronról
- $w_{i,j}$: A kapcsolat erőssége, a j -dik és i -dik neuron között




2. ábra jeláthaladás az i -edik neuronon

A neuronban végbemenő jel transzformációt pedig olyan függvények végzik, amelyek későbbi összegei univerzális approximátoroknak tekinthetők, amelyek alkalmasak függvények tetszőleges pontosságú közelítésére.

$$y_i = f(net_i)$$

ahol,

- y_i : Az i -dik neuront elhagyó jel erőssége



3. ábra A TDK munkámban alkalmazott QNet szoftverben választható jel transzformációs függvények (természetesen a vázolt összefüggések a különböző paraméterekkel torzított (nyújtás-zsugorít, eltolás) függvényvariánsokra is igazak)

A mesterséges neurális hálók tetszőleges pontosságú függvényközelítő képessége a Cybenko – Hornik – Funahashi tétel következménye, amely definiál egy d dimenziós kockát $[0, 1]^d$ és σ szigmoid függvényt (vagy a 3. ábrán jelölt függvények közül valamelyiket). Ekkor a következő függvény

$$f_a(x) = \sum_{i=1}^m v_i \cdot \sigma_i \cdot net_i = v_i \cdot \sigma_i \cdot (w_i^T \cdot x + b_i)$$

sűrű a $D[I^d]$ függvényosztályra nézve. Másként, egy adott $f(x) \in C[I^d]$ esetén és $\varepsilon > 0$ mellett, létezik olyan $f_a(x)$, melyre

$$|f_a(x) - f(x)| < \varepsilon, \quad x \in I_d$$

ahol,


- x : Bemeneti változók vektora

- n : x vektor dimenziószáma futó indexe a j

- $f(x)$: Célfüggvény

- $f_a(x)$: Elemi függvények összegfüggvénye, amelyik tetszőleges pontossággal közelíti az $f(x)$ függvényt. Az elemi függvények darabszáma m , a komponensek futó indexe i

- v_i : Az egyes elemi függvények súlyszám a közelítő az $f_a(x)$ függvényben



4. ábra Cybenko – Hornik – Funahashi tétel grafikus megjelenítése és értelmezése egy két rétegű ANN szerkezeten

- σ_i : Az univerzális approximáló képességekkel rendelkező függvény tetszőleges paraméterű variánsa az i -dik összegkomponensnél.

- w_i : Az i -dik komponenshez, kimeneti csomóponthoz kapcsolódó bemeneti vektorok súlyszám vektora

- b_i : Az i -dik csomóponthoz tartozó bias értéke, ami nem más, mint jel transzformációs függvény függőleges szimmetriatengelyének, vagy középpontos szimmetriapontjának távolsága az origótól, amely egy eltolást reprezentál. (Paláncz 2011) A 3. ábrán bemutatott függvények már a bias eltolással origóra eltolt függvények.

Természetesen a 4. ábra két rétegű neurális hálózata bővíthető, további, úgynevezett rejtett rétegek hozzáadásával is, amely javítja a hálózat összegző képességet. Ezáltal pontosabb közelítéseket végezhetünk komplexebb összefüggések feltárásához. Ugyanakkor a rendszernek így megnő a szabadságfoka is, amely a gráf súlyainak optimalizálását teheti nehezkessé, kevésbé hatékonyá, az eredményeket pedig nem elfogadható pontosságúvá. A QNet kézikönyve (QNet 2000) alapján az összegző képesség a rejtett rétegbeli csomópontok számának növelésével szintén növelhető. Sok csomópont egy rétegbe helyezésénél általában jobb eredményt kaphatunk, ha több, de nem túl sok rétegben helyezzük el az adott számú csomópontot. A rejtett rétegek száma, illetve az alkalmazott csomópontok számának kiválasztása nem triviális feladat, törekednünk kell a lehető legegyszerűbb, de a feladat igényelt pontosságát figyelembe vevő hálózat megalkotására. További szabadságfokot jelent, hogy a QNet szoftverben rejtett és kimeneti rétegeinél különböző transzformációs függvények adhatók meg, amely segítségével hibrid hálózatot is létrehozhatunk. A szigmoid és a tangens hiperbolikus függvény alakjának karakterisztikája más, mint a Gauss –görbe és a szekáns hiperbolikus függvényeké, ezért esetenként hatékonyabb (gyorsabb, pontosabb) futtatásokat hajthatunk végre hibrid hálózatokkal.

3.3. A hálózat súlyainak optimalizálása a backpropagation eljárás

A QNet program a rendszer súlyainak optimalizálásához a hibanégyzet függvény (pontosabban az RMS, de az ismertetett elv ugyanaz) minimalizálását hajtja végre. Véletlen generált súlyokkal felállítva a hálózatot a kimeneten megkapott értéket hasonlítjuk össze a célértékkel, majd a hibát csökkenti az alábbi képletek, összefüggések szerint:

$$E(w, v|x) = \frac{1}{2} \cdot (y - \check{y})^2$$

ahol

- E : hibanégyzet függvény

- w, v : két rétegű hálózat súlyai

- x : bemenetei vektor

- y : célfüggvény

- \tilde{y} : közelítő függvény

A hibafüggvény minimalizációjához, a hálózat súlyainak frissítéséhez ezt követően, azt feltételezzük, hogy a minimumnál a hibanégyzet függvény érintője 0. Ezt a 0 meredekségű értéket ezután iteráció segítségével elsőfokú Taylor polinommal közelíthetjük. Az alábbi képlet a kimenetnél lévő súlyok szerint mutatja a hibafüggvény meredekségének változását numerikus közelítéssel:

$$\frac{\delta E(v_{k+1})}{\delta v} = 0 = \frac{\delta E(v_k)}{\delta v} + \frac{\delta^2 E(v_k)}{\delta v^2} (v_{k+1} - v_k)$$

ahol,

- k : iterációs lépés futó indexe

– $\frac{\delta E(v_{k+1})}{\delta v}$: A hibafüggvény meredeksége a $k+1$ –dik iterációs lépésben, amelyről feltesszük, hogy 0 (0-hoz tart pontosabban).

– $\frac{\delta E(v_k)}{\delta v}$: A hibafüggvény meredeksége a k –dik iterációs lépésben.

– $1/\frac{\delta^2 E(v_k)}{\delta v^2} = \eta$: A hibafüggvény meredekség-változásának reciproka a k –dik iterációs lépésben, amelyről feltesszük, hogy a szélsőérték környezetében konstans. A szakirodalom ezt

az értéket tanulási rátának nevezi. Értékét a futtatások során 0.001-0.01-közöttire vettem fel, átlagosan jól alkalmazható volt a 0.005 érték.

$-(v_{k+1} - v_k) = \Delta v_{k+1}$: A hálózat kimenetén lévő súlyok változtatása a k-dik iterációs lépésben.

A fenti képletet egyszerűsítve, majd a lánc szabályt alkalmazva az alábbi összefüggést kapjuk:

$$\Delta v_{k+1} = -\eta \cdot \frac{\delta E(v_k)}{\delta v} = -\eta \cdot \frac{\delta E(\check{y}_k)}{\delta \check{y}} \cdot \frac{\delta \check{y}(v_k)}{\delta v} = \eta \cdot (y - \check{y}_k) \cdot \frac{\delta \check{y}(v_k)}{\delta v}$$

Ebből látható, hogy a kimeneti függvény felől frissíthető a kimenet felőli első kapcsolatok súlyszámai. A következő rétegek súlyszámainak módosítása az előző logika alapján szintén felírható a kimenet felőli következő réteg hibafüggvényének minimalizálásával. Így egy iterációs lépésben a súlyszámok két réteg között folyamatosan frissíthetőek. Az eljárás neve is, ebből láthatóan, a súlyszámok korrigálásának számítási irányára utal a hálózat bementi-kimeneti alapisírához képest. Mivel ez az eljárás alapvetően egy gradiens alapú optimalizálás, bonyolult „sok hullámot” tartalmazó hibafüggvényeknél könnyen elakadhat lokális szélsőértékeknél az algoritmus. Ezért törekedni kell a lehető legegyszerűbb, de még jól alkalmazható függvényközelítésre. Mivel a rendszer inicializálása véletlen súlyok alapján történik, ezért két egymást követő futtatás eredménye nem feltétlenül egyezik meg, ugyanolyan konfigurációval lefuttatott modellek eredményét a későbbiekben vizsgálom. A QNet algoritmusában a tanulási ráta bizonyos feltételek teljesülése esetén, stabil programfutás esetén megnőhet, illetve instabilitás esetén le is csökkenhet megadott értékekre. A futtatások stabilitását ajánlatos fokozni az α „tehetetlenségi tényező” növelésével is, amely a megelőző iterációs lépés eredményeitől csak csillapítva engedi eltávolodni az új értéket. Ennek általam alkalmazott és a QNet programdokumentációja alapján ajánlott értéke 0.8-0.95.

4. Alkalmazott szoftver

Munkám során a QNet nevű szoftvert használtam az ANN megalkotásánál, illetve a futtások és elemző munka elvégzésénél is döntően. Választásom azért esett erre a programra, mivel az iráni Urima-tónál napos vízszintek előrejelzésénél már sikeresen alkalmazták (*Kavehkar, S. et al. 2011*).

A programról annyit fontos tudni, hogy tetszőleges számú bemenő és kimenő csomópontot és maximálisan 7 rejtett réteget képes kezelni. Az egyes csomópontok közti kapcsolatok szerkeszthetőek (eltávolíthatóak), a számítás iránya az input (bemenő) rétegtől halad a hidden (rejtett) rétegen keresztül az output (kimenő) réteg felé. Az egyes rétegek csomópontjai csak a szomszédos réteg csomópontjaival vannak kapcsolatba közvetlenül.

A súlyok optimalizálás algoritmusá ún. backpropagation elvű, ami azt jelenti, hogy a csomópontok közti élek súlyainak inicializálását a program véletlen szám generátorral végzi, majd a kezdeti súlyokkal végzett számítás kimenetét hasonlítja össze a célértékkel és osztja vissza a hibát a megelőző rétegekre.

Jel transzformációs függvényeket tekintve a program tartalmazza a szigmoid, a Gauss-görbe alakú, a tangens hiperbolikus és a szekáns hiperbolikus függvényeket (a függvények paraméterei 1-ek, tehát vízszintes torzítást nem alkalmaz a program). A QNet a bemeneti réteget kivéve minden rétegen végrehajtja a jel transzformációt, illetve a bemeneti és kimeneti rétegen a megoldást normalizált alakban számolja (bemenetnél ez csak egy ajánlott válaszható opció), amelyet később a program algoritmusá automatikusan visszaalakít normalizálatlan alakra.

A QNet 30 napos próbaverziója ingyenesen letölthető az alábbi linkről <http://qnetv2k.com>.


5. A Medence modell szükségességének tárgyalása

Mint arra a Bevezetőben már utaltam, az ANN képességei, alkalmazásának lehetőségei a számítási munka megkezdésekor nem voltak ismertek számomra. Például, ha elképzelünk egy 1 órás vízszint-előrejelzést úgy, hogy megadjuk bemenetként a megelőző órák vízszintjeit, valamint a megelőző órák és a jövő szélsőségeit, akkor előre nem látható, hogy a háló magától felismeri-e, hogy bizonyos csomópontokon jövőbeli értékek jelennek meg. Kérdés, hogy képes-e az ANN a szél-vízállás ok-okozati függvénykapcsolatát leképezni, vagy az eljárás elsősorban a megelőző, esetleg más pontokra vonatkozó vízállásból következtet-e a jövőbeli vízmozgásra. Milyen időtávlatig alkalmas a modell előrejelzésre, és honnantól kezdve várhatunk legföljebb csak statisztikai egyezést a konkrét időpontra való pontos állapotbecslés helyett? Az sem teljesen egyértelmű, hogy hány korábbi óra befolyásolja érdemben a jövő vízszintjét. A fenti problémát tovább gondolva nem biztos, hogy a múltbeli vízszintértéket reprezentáló számítási csomópont ennek megfelelő részesedést kap-e a végeredményben. Természetesen egyfajta statisztika megjelenik a hálózat súlyaiban, de törekedni kell rá, hogy a fizikai valóság törvényszerűségei és az időbeliség domináljon az eredményekben. A backpropagaton eljárással foglalkozó 4.3. fejezet a súlyok optimalizációjának nehézségeire is felhívja a figyelmet. Előre nem látható, hogy esetleg egy a valóságban még mértékadó múltbeli vízállás figyelembevétele túlbonyolítja-e annyira a hibafüggvényt, hogy lokális szélsőértékeket találunk az iterációval dominánsan a globális szélsőérték helyett. Ezekre az esetekre is kitalálható lenne, egyfajta elősúlyozás, de ez az alkalmazhatóságot jelentősen megnehezíthetné. Ezeket az alapkérdéseket az eredeti feladat leegyszerűsített változatán, egy szabályos téglatest-medencén vizsgálom meg.

6. Medence 1D alapfeladat

6.1. Egyszerűsítő feltevések definiálása

Az egyszerűsítésnél első esetben a legegyszerűbb olyan feladatot próbáltam létrehozni, amely jellegét tekintve hasonlít az eredeti problémához, a balatoni vízszintek előrejelzéséhez. Az egyszerűbb hidraulikai áramlások létrehozásához első lépésbe definiáltam a Balaton átlagméreteivel megegyező medencét, melynek hosszúsága 77000 m, szélessége 7800 m, benne a vízmélység pedig egységesen 3.5 m. Ebben a medencében lévő víztestet „fújattam meg” speciális a hossz- tengellyel párhuzamos (keleti) széllel. A vízszintek kiszámolásához az ACF nevű 2D numerikus hidrodinamikai modellt használtam fel, amely véges térfogat módszer alapján oldja meg a sekélyvízi egyenleteket (Krámer, Józsa 2007). A számítás alapja 1000 m hosszú és 600 m széles téglalapokból álló quadtree-háló, amelyet a peremek mentén besűríttek (legkisebb cellaméret 200m x 300m).

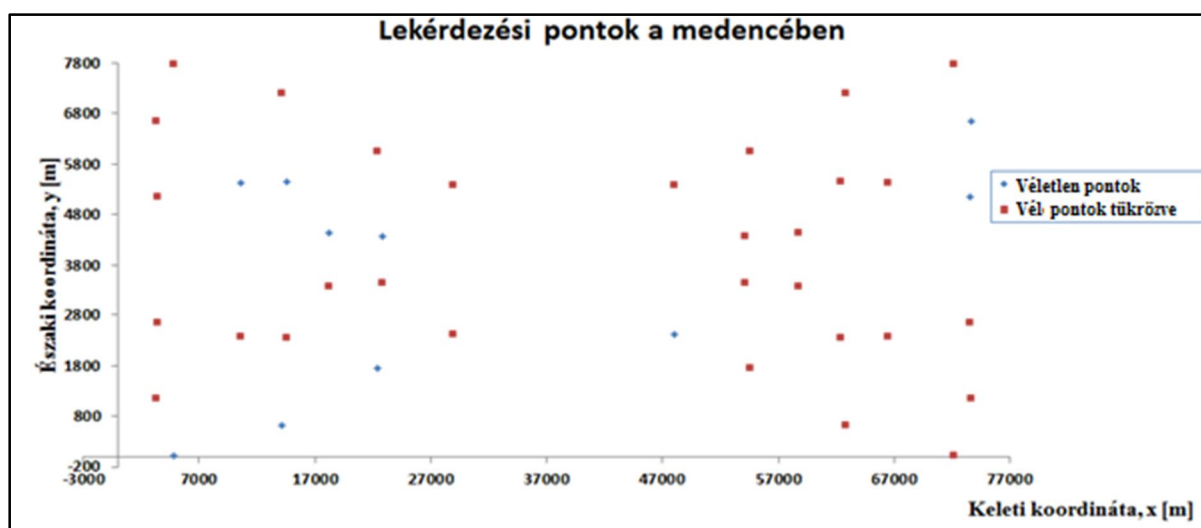


5. ábra A számítási rácsháló a Tecplot (megjelenítést teszi lehetővé) programban x =keleti koordináta, y =északi koordináta m -egységben

A tómodell domborzata és számítási tartománya egyszerűen megszerkeszthető Autocad programmal és ehhez a Dxfproc programot (Krámer 2010) is felhasználtam. Hasonló elven

numerikus modellekkel kalibrált adatokat generáltak már tenger hullámmozgás ANN-nel történő vizsgálatánál (Jaen et al 2011).

Ugyan a vízszint-előrejelzésre a partok mentén van elsősorban igény, ezért az előrejelzés is a partokra kell, hogy összpontosítson. Éppen ezért a későbbi, balatoni vizsgálatoknál nem is elemeztem az ANN előrejelzését a tó belsejében. Egy átfogó kép alkotásához viszont ebben az idealizált teszt-példában a tó belsejében is vizsgáltam a vízszint-ingadozásokat. Azért, hogy a szimmetriatengellyel párhuzamos szelek hatására keletkező tölengések csomópontjait elkerüljem, és hogy feltárjam a tófelszín mozgásának intervallumát 10 véletlenszerűen kiválasztott pontban, illetve ezen 10 pontnak a medence x és y szimmetriatengelyére tükrözéséből előálló pontokba kértem le a vízszintet órás (későbbiekben 10 perces) időközökkel. A véletlenszerűen kiosztott pontok helye a medencében a 6. ábrán, koordinátái az 1. táblázatban találhatóak (a pontok véletlenszerűségét egyenletes eloszlás határozza meg, de egy ún. Halton-sorozat akár szabatosabb lett volna a generáláshoz).




6. ábra *Lekérdezési pontok a medencében (a koordináta rendszer origója a medence bal alsó sarka, viszonyítási magassága 0m –es alapsík)*

A szélességek definiálásánál szintén egyszerűsítettem a valós állapotokat. A szél esetében csak keleti irányba képes fújni, nagysága pedig óránként vált, ezalatt szakaszosan állandó. A szélesség egyenletes eloszlású, 0-10 m/s közötti intervallumban véletlenszerűen van kiválasztva. A teljes idősor hosszát 1023 órára vettem fel. A szél idősor fentiek alapján létrejövő négyszög impulzusai a 7. ábrán figyelhetőek meg. Azért nevezhetjük ezt a szelet 1D-nek, mert a szél párhuzamos a tó hossz tengelyével, és erre merőlegesen nemcsak a meder prizmatikus, hanem a hidrodinamikai megoldás is.

Pont Sorszáma	X [m]	Y [m]
1	73544	5149
2	4852	34
3	14110	610
4	48067	2415
5	22438	1747
6	10563	5423
7	14548	5462
8	73660	6644
9	22839	4361
10	18265	4449

1. táblázat Lekérdezési pontok a medencében



7. ábra az 1023 óráig tartó 1D keleti szél első 100 órája

6.2. Neurális háló 1 óras előrejelzésre

Az első 1D vizsgálatomban egy ANN-t építék fel arra, hogy az 1 óras időközű vízszint- és széladatokból megbecsüljem az 1 órával későbbi vízállást.

6.2.1. Megfelelő hosszúságú idősorok kijelölése

A 6.1. pontban definiált egyszerűsítő feltételek mellett célszerű próbaként egy rövidtávú, alig 1 óras előrejelzést adni a vízszintre az ANN képességeinek első felméréseként. Ehhez olyan feladatot képzeljünk el, amely során rendelkezésünkre áll a múltból tetszőleges n órára átlagos vízszint- és m órára átlagos szélidősor, valamint van a jövőből 1 órára vonatkozó szélesség előrejelzésünk (ennek bizonytalanságával most nem foglalkozok). Ezekből az adatokból szeretnék a következő órában kialakuló átlagos vízszintre előrejelzés készíteni.

Milyen hosszú időre nyúljon vissza a múltbeli adatsor? Pontosabban: a feladat megoldásának első lépéseként meg kell határozni, hogy egy tetszőleges t_0 időpillanat vízszintjét milyen távoli múltbeli szél és vízszint adatok befolyásolják jelentősen (egy héttel korábbi vízszintek gyakorlatilag már nem befolyásolják a jelen vízszintjét, ez érezhető). Egy múltbeli értékekkel való (lineáris) kapcsolat feltárásának klasszikus módszere a korrelációs függvények elkészítése, amelyek megadják a lineáris kapcsolat erősségét két adatsor között az egymáshoz való időbeli eltolás függvényében. Ezt alkalmazhatjuk egyazon vízszint-idősoron belül (ez az autokorrelációs függvény), vagy szél- és vízszint-idősor között is (keresztkorrelációs függvény). Két adatsor korrelációs függvényének értékeit az alábbi képlettel számíthatjuk:

$$k \rightarrow r_{x,y}(k) = \frac{\sum_{i=1}^n (x_i - \frac{1}{n} \cdot \sum_{i=1}^n x_i) \cdot (y_{i+k} - \frac{1}{n} \cdot \sum_{i=1+k}^{n+k} y_i)}{\sqrt{\sum_{i=1}^n (x_i - \frac{1}{n} \cdot \sum_{i=1}^n x_i)^2 \cdot \sum_{i=1+k}^{n+k} (y_i - \frac{1}{n} \cdot \sum_{i=1+k}^{n+k} y_i)^2}}$$

ahol,

- x_i, y_i : Az egyik, illetve a másik adatsor, tetszőleges i -dik eleme (autokorrelációnál ugyanaz a két adatsor) $x_i, y_i \in Q$

- n : Az adatsorok hossza $n \in Z$

- k : Két adatsor közti eltolás $k \in Z$


- $r_{xy}(k)$: Korreláció a két adatsor eltolásának függvényében $r_{xy} \in Q$

A 8. ábrán az 1D szél idősor hatására keletkező medence válasz: a vízállás idősor látható. A 9. és 10. ábra korrelációs függvényei alapján megállapítható, hogy az aktuális vízszintek az egy órával korábbival 0,8 erősséggel korreláltak, és ez a korreláltság a -4. óráig visszamenve fokozatosan nulla közelire csökken. Utána a korreláltság -0,1 és 0,1 között ingadozik. Mindez az összes vizsgálati pontra egyöntetűen kijelenthető.


Az eredményekből arra következtethetünk, hogy lineáris előrejelzéshez a -3, -2 és -1 órai adatokra célszerű támaszkodni, az ennél korábbiakra kevésbé érzékeny az aktuális vízszint. (Természetesen, a 0 eltolású autokorreláció értéke mindig 1.) A szél minden egyes váltásakor gerjesztett hullámok tehát az egyórás időközön túl is meghatározzák a vízszintet, hiszen nem csillapodnak egy óra alatt, hanem ráhalmazódnak a más időpontokban keletkező hullámokra. Ebből következik, hogy a korrelációs függvények elején (kis időeltolásnál) a tavi hidraulika dominál a szélstatistikával szemben. Az viszont nem állapítható meg egyértelműen, hogy ez a következtetés mennyire általánosítható, mert a tó válaszában, és így a korrelációs függvényben is megjelenik a szél impulzusok önkényes, órás időközű szabályos változása és a szélesebességek statistikája is.

Ezek alapján azt várom, hogy a szélidősorban a -3...0. órai adatok, a vízszintekben a -3...-1 órai adatok hatása erős a 0. órai vízszintekre. Ezt kihasználhatjuk az ANN bemeneti adatainak megválasztásánál, és eleve kihagyhatjuk a régi értékeket. A következőkben mégis


kiterjeszttem a bemeneti változókat a vízszinteknél 25 megelőző órára, a szélnél 8 megelőző órára. Ezáltal lehetőség nyílik egy ilyen egyszerű példán igazolni az autokorrelációs függvény kapcsolatát az előrejelezhetőséggel és megállapítani, hogy egy ilyen lineáris függvénykapcsolatot feltételező statisztikai eljárás mennyire használható az ANN tervezésénél.



8. ábra Az 1. pont vízszint idősora, mint a medence válasza a fent definiált 1D keleti szélre



9. ábra Autokorrelációs függvények a véletlen generált medencepontok vízszint idősoraira




10. ábra Keresztkorrelációs függvények a véletlen generált medencepontok vízszintjei és a szélsőségek közt

6.2.2. Neurális háló megépítése referencia esetre

A 6.2.1. pont alapján a QNetben a bemenő csomópontok számát 34-re vettem fel erre a referencia esetre, illetve az előrejelzendő 1 órás átlagos vízszint miatt a kimenő csomópontok száma 1 lett. Tehát az 1023 órás futtatásból (0. óra is van, amikor nyugalomban van a rendszer, tehát 1023+1 órában van) 999 vízszintet tudok előrejelezni, mivel az első előrejelzést a 25. órára tudom végrehajtani a többi időpontot pedig egy órával elcsúsztatva a 25-ös ablakot az 1023-as órával bezárólag. A szélesebbesnél a $-8 \dots 0$. órát veszem figyelembe (tehát 8 órát a múltból és 1 órát a jövőből), így az előrejelzett időpontok számát a 9 órás „szélablak” egyidejű tologatása már nem befolyásolja.

A hálóban 1 db rejtett réteget alkalmazok, amelynek csomópontszáma megegyezik a bemenő réteg csomópontszámával. Fontos megjegyezni, hogy két egymást követő réteg minden csomópontja kapcsolódik a másik réteg minden csomópontjához. A hálózat topológiája a 11. ábrán látható.



11. ábra ANN hálózat vázlatja az 1D Medence feladatnál, 1 órás előrejelzésnél

A hálózati topológia szerkesztő ablakban lehet a QNetben beállítani minden rétegnél külön a jel transzformációs függvényt, illetve bizonyos éleket el is lehet távolítani, ha a feladat indokolttá tenné (Network Design fül). A 999 időpontot TEXT file-ba külön kimentve, hivatkozva kell megadni egy másik ablakban (Training Data fül). A text file szerkezetének olyannak kell lennie, hogy minden egyes oszlopba egy csomópont adatsora legyen megtalálható, az első 34 oszlop tartalmazza így a bemenő csomópontok adatsorát a 35. pedig a kimenőét.

Neurális hálók létrehozásakor fontos szempont az igazolás is, amely egy független adatsorral nemcsak azt általánosító képességet mutatja meg, hanem azt is, hogy a tanítási időszak mérések hibáit, a hiba statisztikáját mennyire tanulta meg az eljárás. Ez a túltanulás kedvezőtlen. Elkerülésére nem a teljes adatsorral végzem a tanítást, hanem az adatsort két halmazra bontom: egy tanuló és egy ellenőrző halmazra. A tanuló halmazból a program optimalizálja a hálózat súlyait, a teszt halmazon pedig leellenőrzi, hogy mennyire állják meg a helyüket más esetekben. A jó alkalmazhatóságnak tehát nemcsak a tanuló halmazon kapott alacsony hiba a feltétele, hanem az is, hogy hasonló nagyságrendű hibát kapjunk az ellenőrző halmazon is. A túltanulás ellenkező problémás esete az alultanulás, amikor a tanulási halmazon a súlyokat még tovább lehetne optimalizálni úgy, hogy ezzel az ellenőrző halmazon is alacsonyabb hibát lehetne elérni. A szakirodalmat olvasva (*Paláncz 2011*) a tanuló és az ellenőrző halmaz elemszámának aránya jellemzően 2:1, 3:1 közötti, ezért én az utolsó 249 időpontot jelöltem az ellenőrző halmazba (a fennmaradó 750-öt pedig tanításra).

Ezek után az előkészítő munkálatok után már csak egy pár paramétert kell megadni, amelyeket érzékenységvizsgálat keretében mutatok be a következő pontban.

6.2.3. Az ANN paraméterezése és érzékenységvizsgálat

Miután elvégeztem a hálózati szerkesztés 6.2.2. pontban ismertetett főbb lépéseit, nem marad más hátra, mint a háló és a futtatási beállítások paramétereinek megadása. A 2. táblázatban az alaphálózaton végrehajtott különböző, a korábbi fejezetekben már tárgyalt főbb beállítások figyelhetők meg az egyes modellfuttatások esetén. Ezeket a futtatásokat REFERENCIA névvel és a változatra utaló sorszámmal jelöltem. A REFERENCIA01 az alapváltozat.

Látható, hogy az első 4 futtatásnál (REFERENCIA02-04) csak a transzformációs függvényt változtattam a rejtett rétegnél. Azért csak a rejtett rétegnél, mert a kimeneti rétegnél csak a szigmoid függvény volt konvergens.

Az 5. és 6. eset megegyezik az 1. és 2.-kal, ennek az a célja, hogy a véletlen generált súlyok hatását vizsgáljam meg végeredmény szempontjából, hogy elakad-e az iteráció más-más lokális szélsőértékeknél. Az 5. esetben módosítottam az iterációs lépések számát is.

Eddig minden futtatásnál éltem az ajánlott normalizációs eljárással. A DHREFERENCIA jelű futtatásnál a normalizáció hatását vizsgáltam: az input csomópontokon szereplő vízszinteket kicseréltem a vízfelszín kilendülésével, mégpedig méter helyett centiméter egységben. A szélsőbességeket pedig változatlanul hagytam. A fizikai információtartalom ebben az esetben is ugyanaz, de a csomópontok közötti nagyságrendbeli eltérés hatása viszont jelentkezhet a 0-tól 1-ig terjedő normalizált skálán is.

Hálózat neve	REFERENCIA01	REFERENCIA02	REFERENCIA03	REFERENCIA04	REFERENCIA05	REFERENCIA06	DHREFERENCIA	DBHIREFERENCIA
Rétegek száma	3	3	3	3	3	3	3	3
Bejövő réteg neve csomópont száma	34=25+9	34=25+9	34=25+9	34=25+9	34=25+9	34=25+9	34=25+9	34=25+9
1. rejtett réteg csomópontszáma	34=25+9	34=25+9	34=25+9	34=25+9	34=25+9	34=25+9	34=25+9	34=25+9
Transzformációs függvény	Szigmoid	Gauss	Tangens hiperbolikus	Szekáns hiperbolikus	Szigmoid	Gauss	Szigmoid	Szigmoid
2. rejtett réteg csomópontszáma	-	-	-	-	-	-	-	34=25+9
Transzformációs függvény	-	-	-	-	-	-	-	Gauss
Kimenő réteg csomópontszáma	1	1	1	1	1	1	1	1
Transzformációs függvény	Szigmoid	Szigmoid	Szigmoid	Szigmoid	Szigmoid	Szigmoid	Szigmoid	Szigmoid
Max Iterációs lépésszám	150000	150000	150000	150000	250000	150000	150000	110000
Tanulási ráta (ETA):	0.005000	0.005000	0.005000	0.005000	0.005000	0.005000	0.005000	0.005000
Tehetetlenség (ALPHA):	0.800000	0.800000	0.800000	0.800000	0.800000	0.800000	0.800000	0.800000

2. táblázat Főbb futtatási és modell paraméterek a 1D Medence feladatnál 1 órás előrejelzésnél (szürke szín jelöli a REFERENCIA01 modellhez képest megváltoztatott paramétert)

A DBHIREFERENCIA jelű futtatásnál 1 rejtett réteg helyett 2-öt alakítottam ki és a korábbi tapasztalatok legkedvezőbb beállításait vettem egy nagy pontosságú futtatás reményében.

A fenti futtatásokat végrehajtva meglepően pontos eredményeket kaptam, amelyek eredményeit grafikusán a 12. ábrán figyelhetjük meg. Gyakorlatilag szabad szemmel nem is lehet különbséget észrevenni a mért és az előrejelzett vízszintek között. Ennél informatívabb ábrázolása az eredmények minőségének a hibafüggvény szerkesztése cm egységben, amely a 13. ábrán található. Ezek alapján kijelenthető, hogy szemre nincs komoly különbség az egyes verzióknál, a DBHIREFERENCIA futtatás talán egy kicsit kisebb hibaszórással rendelkezik.

A részletesebb vizsgálatokhoz érdemes precízebb elemzést előkészíteni, amelyben az egyes verziók jellemző statisztikai mutatószámai jobban differenciálnak. Ezek alapján a 3. táblázat tanúsága szerint a transzformációs függvények közül a (REFERENCIA01-04 esetek) legkedvezőbbnek a Gauss-szigmoid hibrid hálózat bizonyult. A hibanégyzet ennél a verzióknál lett a legkisebb, a hiba átlaga pedig 0, ami szimmetriára utal (átlagosan ugyanannyit téved a rendszer pozitív, mint negatív irányban).

A hibanégyzet összegeket vizsgálva a többi hibrid háló esetén is megjegyezhető, hogy kisebb értékeket kaptunk, mint a homogén szigmatoid hálózatok esetében. A hiba szórása nagyon hasonlóan viselkedik a hibanégyzet összegek alakulásához, tehát a Gauss-sigmatoid kombináció a legkedvezőbb. A maximális pozitív és maximális negatív hiba között külön nem tennék különbséget az egyes verziók között. A relatív hiba nem jelentős.



A normalizáció hatását szintén nem mondanám jelentősnek a DBREFERENCIA futtatásnál (a különbségeket természetesen visszaszámoltam eredeti vízszintekre), körülbelül a homogén szigmatoid hálózatokhoz hasonló eredményeket kaptam, tehát a normalizációnál jelentősebb a transzformációs függvény megválasztásának és a kezdeti súlyok inicializálásának szerepe cm-es víz-vízszintkülönbség (m->cm) torzítás esetén. Ha a futtatások időtartamát (gépidőt)

vizsgáljuk kb 2.5 perc volt szükséges mindegyik esetben, kivéve a kétrétegű DBHIREFERENCIA futtatást, amelynél egy nagyságrenddel megnőtt a futtatási idő (20-30 perc). A megelőző futtatások tapasztalatából merítve ezt a hálózatot szigmoid-Gauss-szigmoid hibrid függvényekkel alakítottam ki. Összességében valós alkalmazáshoz ezt ajánlanám, mivel a hibanégyzet összeg ebben az esetben lett a legkisebb, valamint a hiba átlagot kivéve minden paraméternél ez a verzió nyert. Az 1 mm-es átlagos alulbecslés pedig elfogadhatóan jó érték (bár rosszabb, mint az összes többi esetben).

Nem említettem eddig, hogy ezek a hibanégyzetek a tanulási vagy az ellenőrző halmazra vonatkoznak-e. Az volt a tapasztalatom, hogy a hiba minden ANN-változatnál közel azonos (ezred pontosságú) volt a súlyok iteratív optimalizálása során a tanulási és az ellenőrzési halmazra, azaz az ANN-t nem lehetett túltanítani. A 6. táblázatot ezért a tanuló és az ellenőrző eredmények egymás mögé rakásával készítettem. Ezt alátámasztja az is, hogy a 13. ábra hibafüggvényében a 750-999 között nem változik meg a függvény jellege.

Sorszám	h_i Mérés [m]	refer.01	refer.02	refer.03	refer.04	refer.05	refer.06	dhrefer.	dbhirefer.
		ϵ_i ,hiba [cm]	ϵ_i ,hiba [cm]	ϵ_i ,hiba [cm]	ϵ_i ,hiba [cm]	ϵ_i ,hiba [cm]	ϵ_i ,hiba [cm]	ϵ_i ,hiba [cm]	ϵ_i ,hiba [cm]
max	4.18	3.78	4.15	4.21	4.33	4.14	4.01	4.06	3.26
-max	3.46	-4.58	-4.15	-4.58	-4.05	-4.60	-4.13	-4.58	-3.38
átlag	3.771	-0.04	0.00	-0.01	-0.02	-0.13	0.02	-0.02	-0.12
szórás	0.137	1.25	1.05	1.13	1.11	1.22	1.00	1.22	0.85
szum ϵ^2	-	1554.32	1090.08	1281.68	1227.39	1510.08	995.72	1481.44	732.08

3. táblázat *Különböző előrejelzések hibáinak statisztikai mutatószámai az 1D Medence feladatnál (a legkedvezőbb értékek zöld színnel)*



Miután a végeredményeket számszakilag leellenőriztük, érdemes a következőkben megnézni, hogy az ANN belső szerkezetében tükröződik-e a fizika. Ehhez érdemes megnézni, hogy az egyes bemeneti változók az ANN belső súlyai alapján milyen erős hatással vannak a kimenetre. Ezt az érzékenységet részesedésnek hívja a QNet szoftver, mi is ezt az elnevezést használjuk.


A 14. ábrán az egyes bemenő változóknak (=csomópontoknak) az előrejelzett vízszintekben (=outputhoz) való részesedése figyelhető meg. Az 1-25 csomópontok a megelőző órák átlagos vízszintjét reprezentálják időrendi sorrendben ($t = -25 \dots -1$ h). A vízszintekhez hasonló rendezés szerint 26-33-ig a csomópontok a megelőző órák szélsőértékeit ábrázolják ($t = -8 \dots -1$ h), a 34-es csomópont pedig az előrejelzés órájában ($t = 0$ h) a szélsőértéket. Ezeket a részesedéseket a QNet szoftver számolja ki a betanított rácsháló alapján.

A 14. ábra szerint a bemeneti változók közül a $t = -1$ h vízszintnek a legerősebb a befolyása az 1. pont aktuális, $t = 0$ h vízszintjére. Ezután következik az aktuális, $t = 0$ h szél befolyása. A múltbeli széladatokat nagyon kis mértékben járulnak hozzá a kimenethez, a $t = -6 \dots -2$ h vízszintek hozzájárulása azonban még számottevő. Ha a 14. ábrát összehasonlítjuk a 9. és 10. ábra auto-, illetve keresztkorrelációs függvények abszolút értékével, akkor szembetűnhet, hogy alakjuk nagyon hasonló. Tehát az ANN-nek a korrelációs együtthatóval közel arányosan sikerült súlyoznia az egyes csomópontokat az összes futtatás esetén, eltalálva azt, hogy milyen hosszú közelmúlt van jelentős hatással a jelenre. Persze a különbséget az is okozhatja, hogy a hidrodinamikai kapcsolat a bemenet és a kimenet között nemlineáris, és ezt az ANN le tudja képezni, a korrelációs elemzés viszont nem.

Fontos eredmény az is, hogy az ANN változatok között az egyes bemeneti változók részesedésében csak kis különbségek adódtak. Ez nem csak az ANN felépítéséhez (transzformációs függvények, rejtett rétegek száma, normalizáció) köthető, hanem az egyes

tanítások véletlenszerű lefutásához is. Minden egyes tanítás elején ugyanis a szoftver véletlen értékekkel inicializálja az élek kezdeti súlyát.

Az eredmények alapján érdemi következtetéseket vonhatunk le a további vizsgálatokhoz. A számítások gyorsításához javasolható az ANN redukciója: el lehet hagyni a $t = -25 \dots -7$ h közötti vízszinteket és a $t = -8 \dots -1$ h szeleket a bemeneti csomópontok közül (1-19, illetve 26-32. csomópontok), mivel ezek nagyon kis részben járulnak hozzá a végeredményhez. Ezek az alacsony részesedések akár az optimalizáció numerikus zajának is felfoghatók.



14. ábra Bemenő csomópontok részesedése az 1. pontba előrejelzett vízszintekben 1D


Medence feladatnál a különböző paraméterekkel ellátott ANN futtatások estén

A számítás gazdaságossá tételéhez nem csak a bemenő, hanem a rejtett réteg csomópontszámát is érdemes megvizsgálni. A bemenő réteg és a rejtett réteg, valamint a rejtett réteg és a kimenő réteg összes csomópontja kapcsolódik egymáshoz, ebből kifolyólag annak nincs különösebb jelentősége, hogy a rejtett rétegek csomópontjai milyen sorrendben követik egymást. Tehát a hálózat súlyainak inicializálása határozza meg, hogy egy rejtett rétegbeli csomópont a tanítás végeztével mekkora arányban részesedik a kimenetből. Részesedés szerint viszont érdemes csökkenő sorrendbe állítani a rejtett réteg csomópontjait

is, így megfigyelhetjük, hogy a különböző transzformációs függvényekkel ellátott hálózatoknak mekkora volt a rejtett csomópont igénye.

A 15. ábra alapján megállapíthatjuk, hogy a szigmoid függvénnyel ellátott hálózatok egyenletesebben használták ki a rejtett csomópontokat, mint a hibrid hálózatok. A hibrid hálózatok közül pedig kiemelkedő volt ebben az esetben is Gauss-szigmoid kombináció.

A DBHIREFERENCIA két rejtett rétegből megállapítható az is, hogy az első rejtett réteg szigmoid transzformációja körülbelül ugyanúgy viselkedik, mint az egyrétegű hálózatok szigmoid transzformációi csomópont kihasználtságot illetően, viszont a második rejtett réteg Gauss transzformációt alkalmazó csomóponti aktivitása még inkább egy-egy csomópontra korlátozódik, mint az egy rejtett rétegű Gauss-szigmoid hibrid hálózatoknál. Ezek alapján a legjobb előrejelzést produkáló kétrétegű DBHIREFERENCIA hálózat 29 első rejtett rétegbeli és csupán csak 6 második rejtett rétegbeli csomóponttal is ugyanolyan pontos eredményt adna, hatékonyabb, gyorsabb számítás mellett. Azt sugallja ez, hogy a rejtett rétegek csomópontszámát piramisszerűen célszerű csökkenteni a kimenet irányában.



15. ábra Rejtett csomópontok részesedése az előrejelzett vízszintekben 1D Medence feladatnál a különböző paraméterekkel ellátott ANN futtatások estén

7. Medence 2D alapfeladat valós szél esetén

7.1. Egyszerűsítő feltevések definiálása és a megfelelő hosszúságú idősorok kijelölése

A 6. fejezetben a medence alapfeladatra megfelelő pontosságú, a gyakorlatban is felhasználható előrejelzéseket kaptam. Megállapítottam, hogy az ANN bemeneti változói közül a szél és a vízállások alig néhány órával korábbi értékei érvényesülnek az előrejelzett vízszintben, és a következőkben így eleve ezekre lehet csökkenteni a bemeneti változókat, ezáltal csökkentve az ANN bonyolultságát.

Érdekes tovább vizsgálni az előrejelzés lehetőségeit, elmozdulva a valóság és a szélesebb körű alkalmazhatóság felé. Az ANN előrejelző képességét ebben a második tesztfeladatban egy valós, szabálytalan szélidősorral vizsgálom, továbbra is a Balatont befoglaló, idealizált téglatest alakú tóban. Az összehasonlítás itt is az ACF hidrodinamikai modell által számolt vízszintekkel történik.

A korábbi modell 1D szintetikus, szakaszosan konstans szélidősorát ezért lecseréltem 2009.06.06 – 2009.09.06 között mért (BIR 2012) és a logaritmikus sebességprofillal 10 m-re feltranszformált Siófoki tóközépi szélidősorra. A jelölt időszak szélesebbeségei keleti és északi komponensekre bontva a 16. ábrán szerepelnek. Mivel ezeket a szélesebbeségeket is óras átlagolással kaptam, ezért az egyes óras átlagos szélesebbeségeket négyszögimpulzusokként adtam meg a hidrodinamikai modellbe a válasz vízszint idősor számításánál.

A hidrodinamikai modellel meghatározott vízszint idősor alapján megszerkeszttem az óras vízszint autokorrelációs-, az (óras keleti szélesebbesség-komponens) – (óras vízszint) keresztkorrelációs, valamint az (óras északi szélkomponens) – (óras vízszint) keresztkorrelációs függvényeket. A vízszint idősort a 17. ábrán, a korrelációs függvényeket a 18-20. ábrákon lehet meg szemlélni. Megfigyelhető, hogy itt a korreláltság jóval korábbi

állapottal is kimutatható, mint az előző, szabályosabb feladatban. Ennek az okát nem vizsgáltam, de sejthető, hogy a szélmeghajtás hosszabb időszakon kimutatható autokorrelációja az oka. Az előző példában a szél csak 1-1 órán belül volt korrelált, míg a mostani feladatban előírt valós szélidősornál az időjárási frontokból ennél sokkal hosszabb viharok fordultak elő közel azonos irányból. A hosszabb szélcsendes időszakok is növelik a nagyobb időeltoláshoz tartozó autokorrelációt.

Mindezt figyelembe véve, a korrelációs függvények alapján a $t=0$ h vízszint előrejelzéséhez a neurális hálóba $t=-17\dots-1$ h vízszinteket és $t=-20\dots 0$ h északi szélesség komponensét ajánlom figyelembe venni, ugyanis ezeknél haladta meg a keresztkorreláció ill. az autokorreláció a 0,1-es alsó küszöbszintet. Tehát összességében $17+21*2 = 59$ bemeneti és 1 kimeneti csomópontból fog állni a modellem, egy db, 59 csomópontot tartalmazó rejtett réteg alkalmazásával.


A futtatások eredményeit szemlélve az 1D medencemodellhez képest kétszer akkora hibanégyzet összegeket kaptam (kb kétszer olyan hosszú az adathalmazom is), valamint kissé, de nem számottevően megnőtt a hiba szórása és az átlaga is.

Itt is meghatároztam a bemenő csomópontok hozzájárulásának mértékét az előrejelzéshez (az ábrát itt nem közlöm). Ezeknek az alakja itt is hasonlóan adódott a korrelációs függvényekéhez. Ezen eredményeket felhasználva a hálózat bemeneti csomópontjait redukáltam $t=-11\dots-1$ h vízszintekre és $t=-5\dots 0$ h keleti szélességet. A rejtett réteg csomópont számát szintén redukáltam 17-re.


Érdekesség, hogy az északi szélességek számottevően nem befolyásolják az óras előrejelzett vízszinteket! Először ennek olyan okát valószínűsítettem, hogy a keresztirányú lengésidő rövidebb, mint az ANN 1 órás időfelbontása, így a keresztirányú hullámmozgás nem képezhető le az ANN-ben. Valóban, a Nyquist-féle mintázási tétel értelmében legfőbb $45/2$

= 22,5 perces időköz engedhető meg ahhoz, hogy a kb. 45 perces periódusú keresztirányú állóhullámokra a diszkrét jelből következtetni tudjunk. Okként felmerült még az is, hogy az (1. sz.) megfigyelési pont közel volt a keresztirányú lengés csomópontjához. Ezt a két okot többi pont ill. rövidebb időlépés vizsgálatával ki lehetne zárni vagy meg lehetne erősíteni. Erre ugyan nem tértem ki a munkámban, de a későbbi, balatoni eredmények (8. fejezet) azt mutatják, hogy a siófoki vízszintelőrejelzés mégis érzékeny az északi szélkomponensre. Tehát az ok valószínűleg az, hogy a megfigyelési pont közel volt a hullám álló helyzetű csomópontához.

A következőkben a 17 bemeneti és rejtett csomópontra redukált ANN-en folytatom a vizsgálataimat.




16. ábra Szélsebesség idősorok keletre, illetve északra mutató komponensekkel Siófokon (BIR) 2009.06.06 – 2009.09.06 között



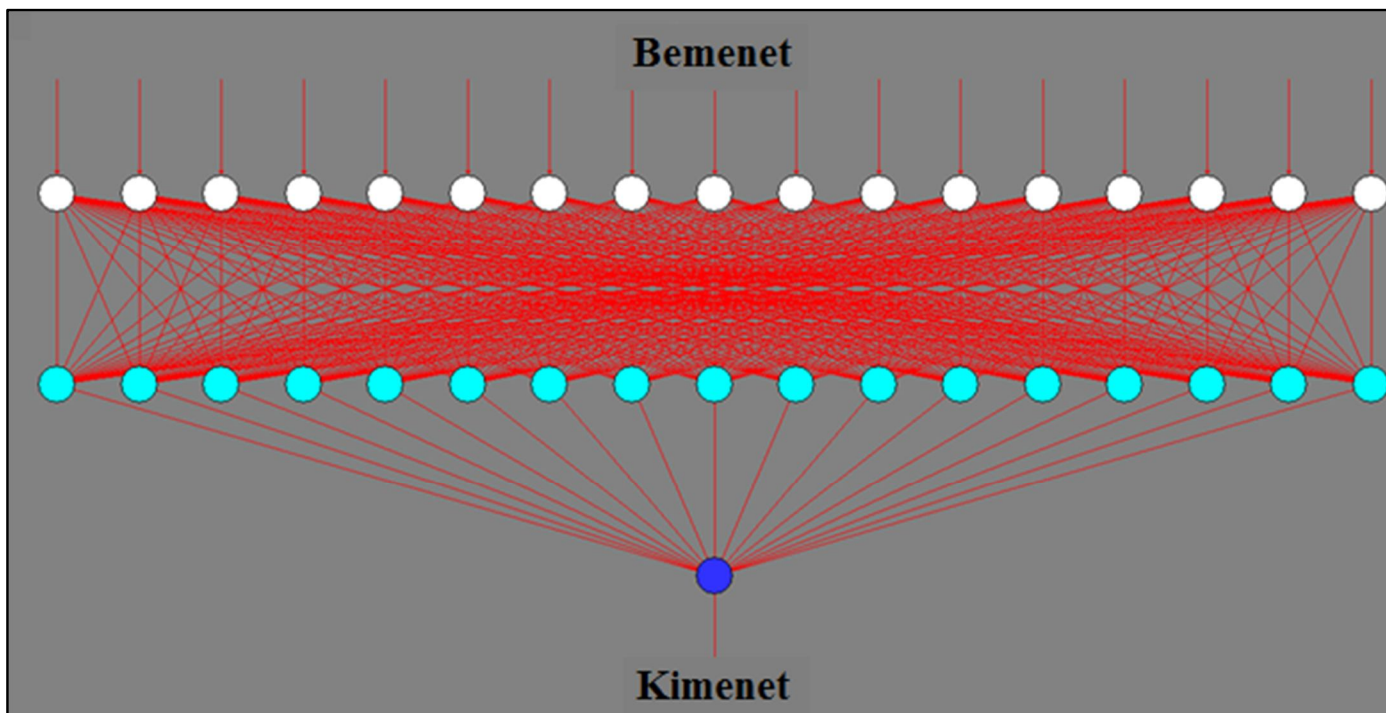


19. ábra Keresztkorrelációs függvények különböző medence pontok vízszint idősoraira és a keleti szélesség komponensre



20. ábra Keresztkorrelációs függvények különböző medence pontok vízszint idősoraira és az északi szélesség komponensre

7.2. Egy óras előrejelzés készítése redukált csomópontú neurális hálón



21. ábra Redukált referencia hálózat a 2D Medence feladatnál 1órás előrejelzésnél


Miután a QNetben megszerkesztettem a redukált hálózatot, amely a 21. ábrán megismerhető a 6. pont metodikája szerint ebben az esetben is megvizsgáltam a különböző transzformációs függvényekkel kapott előrejelzéseket. A redukált hálónak bevezetéséből adódóan már a nyári időszak 11. órájára (0.-tól számolom az órákat) tudok vízszintet előrejelezni, tehát összesen 2198 előrejelző esetem van, amelyből az első 1600 órát használom fel a háló tanítására. A futtatás és a háló főbb paraméterei a 4. táblázatban találhatók.

Mindenképpen szempont volt a 2D vizsgálatnál, hogy több eseten tudjon tanulni az ANN, mint az 1D Medence feladatnál, mivel egy összetettebb hatás megtanulása több példát igényel. Ez akkor is hasznos, ha a csomóponti redukció hatására kvázi 1D-s feladat keletkezik, mivel a több elemű halmazon tanulás lehetősége a jobb általánosító készséget is magával vonhatja. Több példán tanulás esetén ráadásul egy összetett, valós szélhatás –válasz kapcsolatot elemezve óhatatlanul nagyobb hibákat várhatunk, mint az 1D-s szabályos periódusidejű négyszögimpulzussal adott szélhatás esetén. Az általánosabb folyamat megtanulása miatt, ugyanakkor lassabb konvergenciát várok az ANN-től, ezért 100 000 iterációs lépést adtam meg a


futtatásoknál, ami egy nagyságrenddel több, mint az 1D kísérlet esetén. A 22. ábrán a tanuló halmaz RMS hibájának változása látható az iterációs lépés függvényében. Az ábrából megállapítható, hogy a gradiens módszer iterációja elején nagyobb a hiba változékonysága, kiugró értékekkel, majd a (lokális) optimum környezetében a hiba már monoton csökkenéssel konvergál egy minimális értékhez. A 60 000 lépéstől gyakorlatilag nem történik érdemi változás a hibafüggvényben. Az ellenőrző halmaz esetében is hasonlóan magas korrelációs együtthatót tapasztaltam, és azt, hogy a pillanatnyi súlyokkal a tanuló és az ellenőrző halmazra kapott hiba az iterációs lépés függvényében egészen hasonlóan mozgott együtt.

Hálózat neve	REDREFERENCIA01	REDREFERENCIA02	REDREFERENCIA03	REDREFERENCIA04
Hálózati rétegek száma	3	3	3	3
Input csomópontok száma	17=11+6	17=11+6	17=11+6	17=11+6
1. Rejtett réteg csomópontjainak száma	17=11+6	17=11+6	17=11+6	17=11+6
Transzformációs függvény	Szigmoid	Gauss	Tangens hiperbolikus	Szekáns hiperbolikus
Output csomópontok	1	1	1	1
Transzformációs függvény	Szigmoid	Szigmoid	Szigmoid	Szigmoid
Teszt esetek száma	598 (2198-az összes eset)	598 (2198-az összes eset)	598 (2198-az összes eset)	598 (2198-az összes eset)
Iterációszám	100 000	100 000	100 000	100 000
Tanulási ráta (ETA):	0.005000	0.005000	0.005000	0.005000
Tehetetlenség (ALPHA):	0.800000	0.800000	0.800000	0.800000

4. táblázat Főbb futtatási és modell paraméterek a 2D Medence feladatnál 1 órás előrejelzésnél (szürke szín jelöli a referencia modellhez képest megváltoztatott paramétert)



22. ábra Tanuló halmaz RMS hibafüggvénye az iterációs lépések függvényében REDREFERENCIA01 futtatásnál



23. ábra REDREFERENCIA01 futtatás előrejelzett értékeinek és a célértékeknek a viszonya

A 23. ábrán a tanuló és az ellenőrző halmazra kapott előrejelzés láthatjuk a célértékek függvényében, mindkét tengelyt normalizálva 0–1 közé. Ez alapján megállapítható, hogy a két halmazon kapott előrejelzések hasonló jellegűek és mindketten kis szórással, jól közelítik a célértékeket. Az ilyen jellegű illeszkedés az összes futtatási verziónál jellemző volt, nem csak a REDREFERENCIA01-nél.

Magát a hidrodinamikai modelleredményt és a különböző ANN-futtatások előrejelzéseit megfigyelhetjük a 24. ábrán, ahol az 1D futtatáshoz hasonlóan szintén nem látható jelentős eltérés. A hibafüggvényt tekintve a 25. ábrán teljesen hasonló karakterisztikát kaptam, mint 1D esetben. Az egyes futtatások pontosabb elemzéséhez az 5. táblázatban megismerhetők a statisztikai mutatók is. Ezek alapján megállapítható, hogy arányaiban hasonlóan teljesítenek a különböző jeltranszformációs függvényekkel ellátott modellek, mint az 1D esetben. A hibaátlag és a hibaszórás gyakorlatilag egyezik az 1D- nél tapasztalt értékekkel. Lényegi különbséget egyedül a maximális pozitív és negatív hibában találtam, amely kétszeresre, háromszorosra nőtt az 1D eseteihez képest. Tehát a megnövekedett esetszám és az 1 szóráson kívül eső szélsőségek felelősek leginkább a hibanégyzet összeg megnövekedéséről. Ennek ellenére a 25. ábrán a valóban nagy, 5cm-nél nagyobb hibaértékek ritkák. Egy teljes nyári időszakhoz viszonyítva a 10–20 óra pontatlan előrejelzés nem



nagy arányú, de több nagy hiba éppen a legnagyobb vízszint-kilendüléseket terhelte. A többi esetben pedig kifejezetten pontos előrejelzésről beszélhetünk, amit a betanítás után a hidrodinamikai modellhez képest jóval rövidebb számítási idővel elérhetünk.

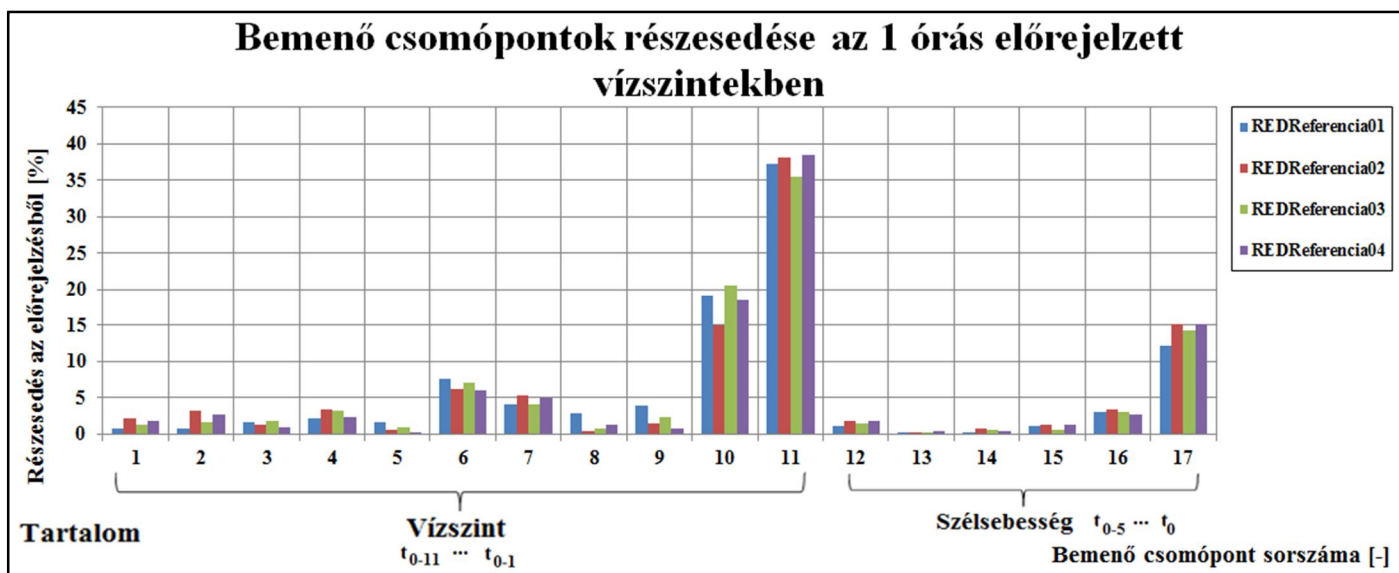
Az 5. táblázat alapján a legjobban a Gauss-szigmoid (REDREFERENCIA02) és a Tangens hiperbolikus-szigmoid (REDREFERENCIA03) hibrid hálók teljesítettek legjobban, és ezek konvergencia-sebesség és stabilitás szempontjából is jó választások. Tájékoztatásul: 20–30 perc alatt futott le ezeknek a tanítása egy kétféls magos I5-ös processzorú laptopon.

Sorszám	h_i modellezett [m]	redreferencia01	redreferencia02	redreferencia03	redreferencia04
		eps _i ,hiba [cm]	eps _i ,hiba [cm]	eps _i ,hiba [cm]	eps _i ,hiba [cm]
max	4.46	12.04	7.73	8.91	7.83
-max	3.05	-8.61	-9.90	-8.06	-9.58
átlag	3.57	0.13	-0.01	-0.04	-0.01
szórás	0.16	1.13	1.03	1.03	1.07
szum eps ²	-	2860.90	2345.28	2312.68	2528.38

5. táblázat 1 órás előrejelzések hibastatisztikája 2D Medence feladatnál (a legkedvezőbb értékek zöld színnel)

A bemenő csomópontok redukciója után a csomóponti részesedéseket figyelve ebben az esetben is megfigyelhető a korrelációs függvények alakisága. A csomópont-redukciónál addig az időpontig mentem vissza a múltba, amikor még 3% részesedés megfigyelhető volt eredetileg a redukálatlan hálónál (tehát előfordulhat 3%-nál kisebb érték is a t_0 és a legtávolabbi 3%-os múltbeli érték között). Ezek alapján a redukált hálónál elég pontosan visszakaptam a redukálatlan háló megfelelő csomópontjainak a részesedését (26. ábra). Összességében megállapítható a 26. ábra és a korrelációs függvények alapján, hogy a neurális háló feltárta a fizikai folyamatokat és képes kellő pontosságú előrejelzést adni egy ilyen hidrodinamikai modellel kapott vízszintekre.





26. ábra Bemenő csomópontok részesezése az 1. pontba előrejelzett vízszintekben 2D Medence feladatnál a különböző paraméterekkel ellátott ANN futtatásoknál

7.3. Hét órás előrejelzés készítése a redukált csomópontú neurális hálón

Mivel a hálózat az 1 órás előrejelzésre jól vizsgázott valós szélviszonyokkal meghajtott medence modell esetén, érdemes hosszabb távra előrejelezni, azaz az 1 órás előrejelzést további órákkal bővíteni. Mivel a tó lengéseideje hosszirányban kicsit több, mint 7 óra, ezért célszerűen ugyanilyen hosszú, 7 órás előrejelzést választottam. Milyen változást jelent ez az ANN felépítésében?

Kétféleképpen is eljárhatnánk a 7 órás előrejelzésnél.

- 1) Az előbb bemutatott ANN-nel hétszer lépünk előre 1-1 órát úgy, hogy a $t=1 \dots 6$ órában fokozatosan belépnek az előrejelzett vízszintek a bemeneti adatok közé.
- 2) Az ANN-nel egy lépésben jelezzük előre a $t=0 \dots 7$ h vízszinteket, ezeknek a kapcsolatát külön-külön tanítatjuk meg a $t=0$ előtti bemeneti vízszintekkel.

Ez utóbbit választottam, a kimenő csomópontba tehát a hét jövőbeli órához tartozó vízszinteket adtam meg.

Feltételezve, hogy a jövőbeli szélidősor előrejelzése rendelkezésünkre áll, a 7.2. pontban bemutatott,

redukált hálózat bemenő csomópontjait megtoldottam további 6 jövőbeli szél csomóponttal ($t=1 \dots 6$ h). A 23 bemenő csomópont mellé ugyanennyi rejtett csomópontot is definiáltam 1 rétegben.

Tehát, ha egy mérőállomáson vannak vízszint-méréseim és szél-előrejelzéseim, akkor vízszint-előrejelzéseket tudok ezekből készíteni. A korábbi tapasztalatok szerint az így kialakított ANN előrejelzésének első órájában a megelőző óra vízszintjét várom dominánsnak, majd az időben előre haladva az előrejelzéseknél egyre kevésbé hangsúlyosnak. Ezt a súlycsökkenést, reményeim szerint az idő előrehaladtával egyre inkább az aktuális szélesebesség kompenzálja majd.

Teljes mértékben kapcsolódó csomópontok esetén a jövőbelátás esete kérdéses. Fizikailag természetesen egy t időpontba előrejelzett vízszintet nem befolyásolhatja a későbbi szél. Vajon az ANN képes-e önmagától megtanulni ezt, és minimális részesedést ad-e az előrejelzést követő széladatoknak? A 6. táblázatban szereplő REFERENCIA modell megengedi a jövőbelátás lehetőségét, a korábban már felvázolt 23-23-7-es hálószerkezet szerint. A jövőbelátás lehetőségének kizárására jó eszköz a rejtett réteg csomópont számainak megnövelése és bizonyos csomópontok közötti kapcsolatok elvágása. Ennek értelmében az új, STRUKTREFERENCIA nevű hálózat rejtett rétegének első 17 csomópontja kapcsolódik az első kimeneti csomóponthoz, amely a $t=0$ h előrejelzést reprezentálja. Az egy órás előrejelzéshez 17 független rejtett csomópontot alkalmaztam. A $t=1$ h előrejelzéséhez létrehoztam 18 új rejtett rétegbeli csomópontot, amely a múlt 17 órájához és a jövő óra első órájához ($t=1 \dots 1$ h) is csatlakozik, valamint a kimeneti rétegben csak a $t=1$ h előrejelzést reprezentáló csomópontot kapok (a bemeneti és a kimeneti réteg csomópontszáma természetesen nem változik a REFERENCIA modellhez képest). A hálózati kialakítások a 27. ábrán láthatók.

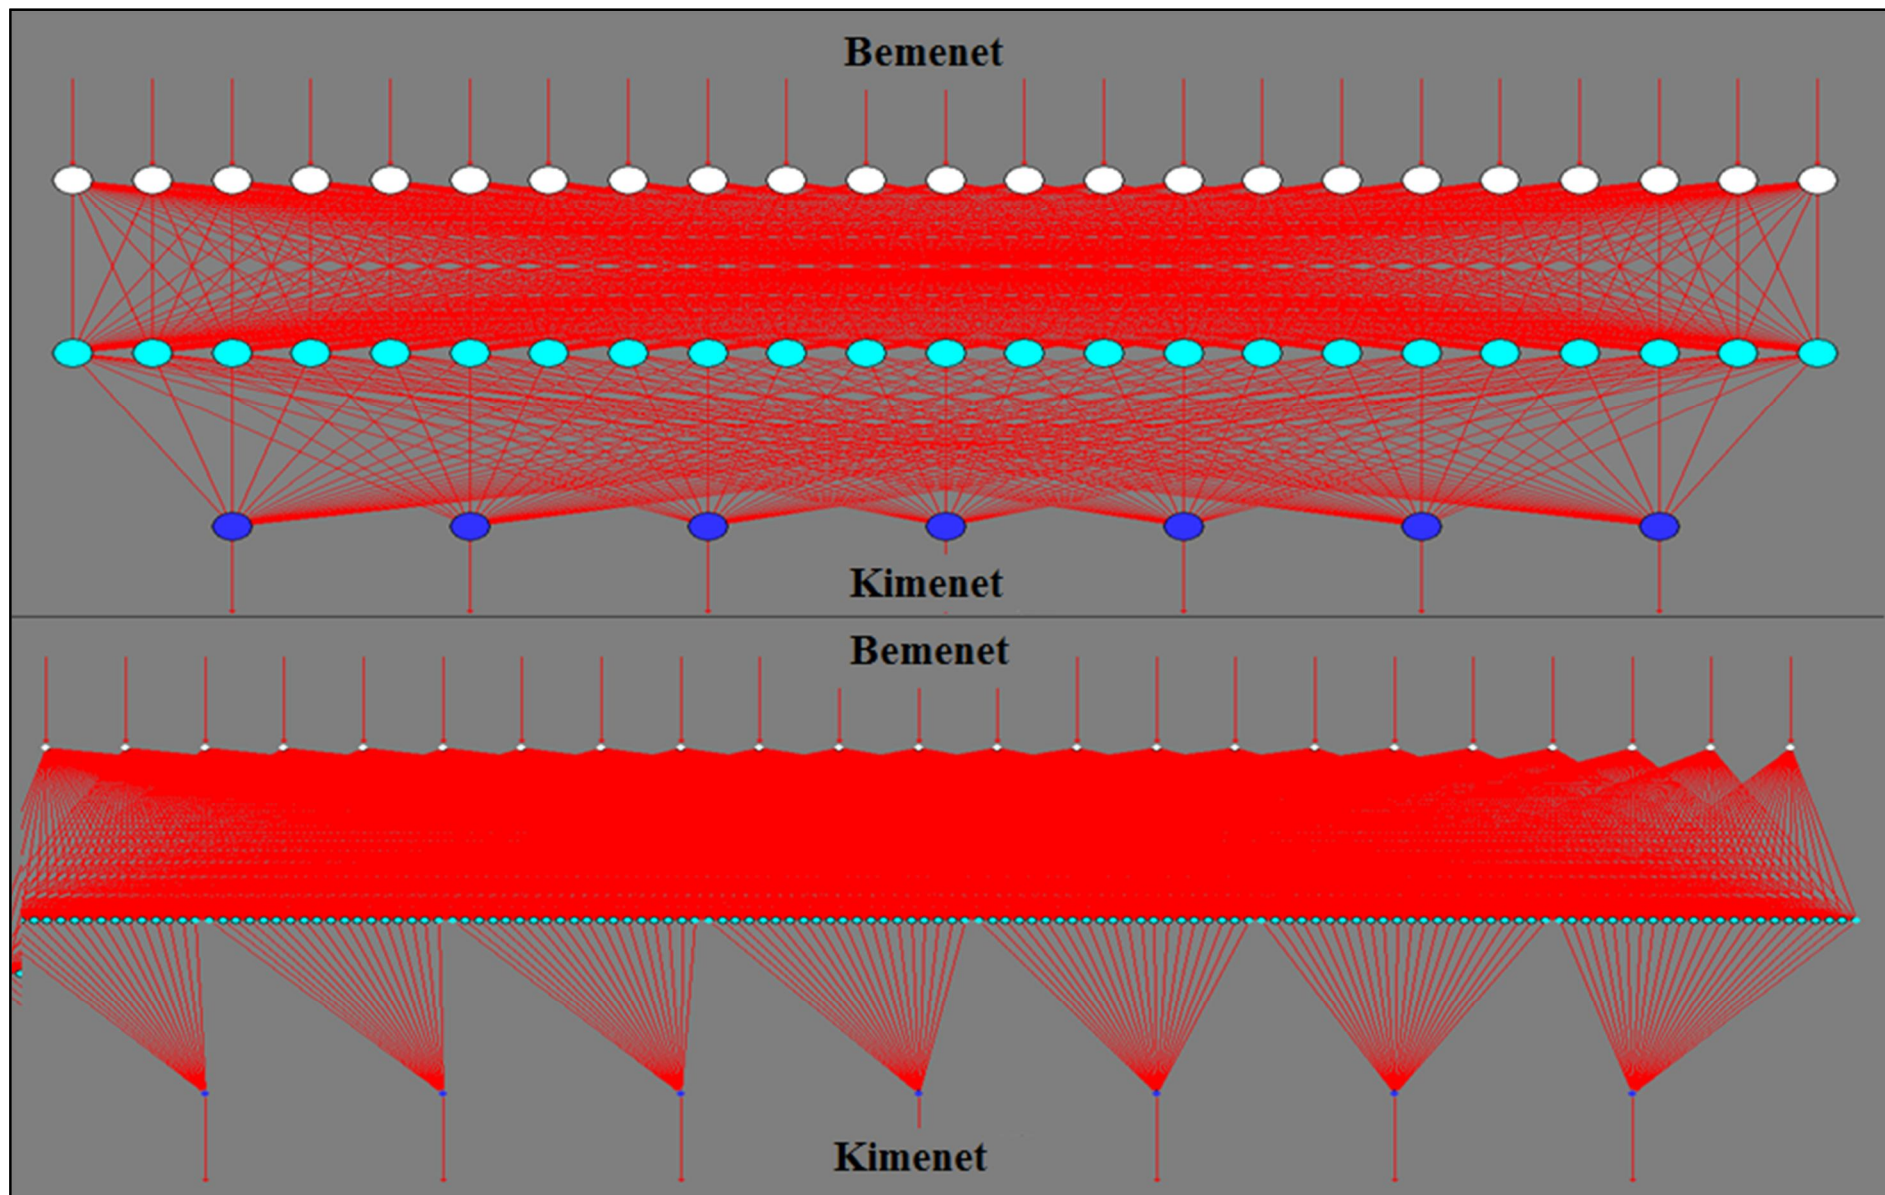
A 6. táblázat futtatási paramétereit szemlélve megállapítható, hogy hibrid (a bemeneti-rejtett és a rejtett-kimeneti éleken eltérő transzformációs függvényt alkalmazó) hálózatok közül csak egy szerepel, mivel ezekben a hálózatokban a gradiens módszer nem működött jól, valószínűleg rögtön az elején egy magasabb lokális optimumba ragadtak be. Egyedülként sok próbálkozás után a tangens hiperbolikus-szigmoid

hálózatot tudtam konvergenciára kényszeríteni a tanulási ráta alacsonyabbra vételével, illetve a tehetetlenség megnövelésével a vegyes hálózattípusok közül.

A futtásoknál hosszú, 100 000 lépéses iterációt adtam meg, mert a korábbi egyetlen kimeneti csomópont helyett ezúttal hét csomópont van. A STRUKREFERENCIA03 változatban még azt is megvizsgáltam, hogy a STRUKREFERENCIA02 változathoz képest további 50 000, azaz 150 000 iterációs lépéssel érünk-e el javulást. A magas iterációs lépésszám az RMS hibafüggvény konvergenciáját figyelve indokolt volt.

Hálózat neve	REFERENCIA	STRUKTREFERENCIA01	STRUKTREFERENCIA02	STRUKTREFERENCIA03
Rétegek száma	3	3	3	3
Input csomópontok száma	23=11+12	23=11+12	23=11+12	23=11+12
1. Rejtett réteg csomópontjainak száma	23=11+12	140	140	140
Transzformációs függvény	Szigmoid	Szigmoid	Szigmoid	Tangens hiperbolikus
Gráfszerk. Élkapcs. Bemenő és 1. Rejt. rétegek között	teljes	részleges	részleges	részleges
Kimenő csomópontok száma	7	7	7	7
Transzformációs függvény	Szigmoid	Szigmoid	Szigmoid	Szigmoid
Gráfszerk. Élkapcs. 1. Rejt. és Kimenő rétegek között	teljes	részleges	részleges	részleges
Teszt esetek száma	592 (2192-az összes eset)	592 (2192-az összes eset)	592 (2192-az összes eset)	592 (2192-az összes eset)
Iterációszám	100 000	100 000	150 000	100 000
Tanulási ráta (ETA):	0.005000	0.005000	0.005000	0.004000
Tehetetlenség (ALPHA):	0.800000	0.800000	0.800000	0.900000


6. táblázat Főbb futtatási és modell paraméterek a 2D Medence feladatnál 7 órás előrejelzésnél (szürke szín jelöli a referencia modellhez képest megváltoztatott paramétert)




27. ábra REFERENCIA (felső) és STRUKTREFERENCIA (alsó) hálózati modellek a QNetbe 7 órás előrejelzéshez

A másik fajta hibaanalítika az egyes csomópontok viselkedését vizsgálja az előrejelzés időbeli hatótávolságának jellemzésére. A 7. táblázat eredményeit figyelve megállapítható, hogy legjobban a hibrid-hálózat teljesített. A főlény egyértelmű a hiba négyzetösszeg és a szórás mutatókra minden órában. Jól teljesített még a hibrid hálózat a maximális hibáknál is, ahol a legtöbb órán itt kaptam a legkisebb értéket, illetve a hiba átlagoknál is jó volt a teljesítmény (a legkedvezőbb értékektől csak egy kissé tért el). A maximális negatív hiba esetén egyértelműen a REFERENCIA modell nyert. A táblázatból az is megállapítható, hogy a STRUKTREFERENCIA01-02 futtatásoknál a több iterációs lépést engedő modell egy kissé jobban szerepelt. A számszaki megállapítások alapjait leellenőrizhetjük a 29, 34-35 ábrákon is. Ezen kívül a grafikonos ábrázolás lehetőséget ad tartalmi elemzésre is. Mind a hibasávnál, a hiba négyzetösszegnél és a hiba szórásnál az eredmények egy szétnyíló ollóra hasonlítanak, amely kinyílása a előrejelzés időben növekvő bizonytalanságát reprezentálja. Ez alól kivétel a REFERENCIA futtatás $t=3$ h-ra vonatkozó előrejelzése, amely nem illik a korábbi és későbbi adatok trendjébe, így elképzelhető, hogy egy anomália. Ebben az esetben csak numerikus optimalizáció történt. A fentiek tükrében alkalmazhatóság szempontjából egyértelműen a STRUKREFERENCIA03 hibrid hálózatát ajánlom.


A grafikonok további elemzésével megállapítható, hogy a hiba szórása a kezdeti 1cm körüli értékről 3 centiméter körülire nő a $t=6$ h-ra, a maximális hibák a hibasáv mindkét oldalán (a pozitív oldalon nagyobb a bizonytalanság) több mértékadó percentilis értéket kipróbálva 2-2,5 szerezre nőnek az előrejelzés végére, valamint a hiba négyzetösszeg 7-8 szorosára nő.




28. ábra STRUKTREFERENCIA03 vízszint-előrejelzése és a modellezett célértékeknek a viszonya




29. bra Hibasv vltozsa az elrejelzs idbeli elrehaladtval a klnbz ANN vltozatoknl




30. ábra 7 órás előrejelzés hibaidőszora a 2D Medence feladatnál, REFERENCIA változatnál. A görbék az egyes időpontokban a $t=0\dots6$ h-ra adott előrejelzések hibáinak burkolóit és átlagos értéküket mutatják.



31. ábra Ugyanaz, mint a 29. ábrán, de a STRUKTREFERENCIA01 változatnál




32. ábra Ugyanaz, mint a 29. ábrán, de a SRTUKTREFERENCIA02 változatnál




33. ábra Ugyanaz, mint a 29. ábrán, de a SRTUKTREFERENCIA03 változatnál

Statistikai mutató típusa	Modellezett vízszint [m]	Előrejelzés hibastatisztikája [cm]							ANN modellek
		1. órás előrejelzés	2. órás előrejelzés	3. órás előrejelzés	4. órás előrejelzés	5. órás előrejelzés	6. órás előrejelzés	7. órás előrejelzés	
max	4.463	8.22	15.08	14.50	26.63	19.99	18.80	23.19	REFERENCIA
-max	3.054	-8.82	-12.71	-13.83	-46.25	-20.71	-22.88	-23.80	
átlag	3.054	-0.36	-0.08	0.18	0.30	0.37	0.41	0.42	
szórás	0.157	1.38	1.88	2.37	5.26	3.02	3.05	3.27	
szum eps ²	-	4477.86	7796.98	12365.03	60756.67	20262.34	20763.67	23771.27	
max	4.463	14.27	21.78	17.65	21.43	29.29	30.95	31.96	STREKTREFE01
-max	3.054	-9.14	-16.69	-18.67	-21.00	-22.19	-24.00	-24.40	
átlag	3.054	0.09	0.00	0.02	0.01	0.25	-0.03	-0.01	
szórás	0.157	1.17	1.94	2.39	2.74	3.11	3.27	3.27	
szum eps ²	-	3028.27	8269.57	12552.30	16457.70	21319.95	23443.40	23421.44	
max	4.463	10.23	23.94	17.82	16.67	19.82	19.86	27.40	STREKTREFE02
-max	3.054	-8.47	-16.11	-19.39	-21.00	-23.63	-24.54	-25.22	
átlag	3.054	-0.09	-0.01	-0.63	0.00	0.01	0.01	-0.34	
szórás	0.157	1.05	1.91	2.52	2.70	2.88	2.91	3.24	
szum eps ²	-	2418.45	7972.50	14795.73	15966.43	18149.19	18561.85	23291.45	
max	4.463	9.48	11.42	10.92	19.48	14.08	19.86	14.11	STRUKTREFE03
-max	3.054	-8.19	-15.77	-18.29	-20.01	-22.80	-24.33	-24.02	
átlag	3.054	-0.04	-0.04	-0.06	0.01	0.00	-0.03	0.02	
szórás	0.157	0.98	1.53	1.97	2.42	2.55	2.73	2.73	
szum eps ²	-	2107.67	5136.89	8492.78	12791.18	14257.74	16380.62	16301.41	

7. táblázat A 7 órás előrejelzés hibastatisztikája 2D Medence feladatnál (a legkedvezőbb értékek zöld színnel)



34. ábra A hiba-négyzetösszeg változása az előrejelzés időbeli előrehaladtával a különböző ANN változatoknál




35. ábra A hiba szórásának változása az előrejelzés időbeli előrehaladtával a különböző ANN változatoknál

A neurális háló előrejelző képességét, a fizikai folyamatok megtanulását leellenőrizhetjük a bemenő csomópontoknak az adott órás előrejelzésekhez való hozzájárulásaiból. A $t=0$ h előrejelzésnél a 36. ábrán hasonló hozzájárulásokat kaptam, mint amikor csak egy órára készítettem előrejelzést a 7.2. pontban. Látszik, hogy legnagyobb befolyással az előrejelzést megelőző $t=-1$ h vízszint rendelkezik a 11. csomópontnál, majd a korrelációs függvényhez hasonlóan a részesedés fokozatosan lecsökken az 1 csomópontig ($t=-11$ h vízszint). A 12-17. csomópontok a $t=-5...0$ h szélességeket reprezentálják, a hozzájárulásuk a keresztkorrelációs függvényhez hasonlóan adódott. Az előrejelzés $t=0$ h időpontját követő

18-23 szélsébség csomópontok ($t=1\dots6$ h) a REFERENCIA futtatás esetében ugyan kicsi, de nullánál mégis nagyobb súllyal szerepelnek annak ellenére, hogy fizikailag nem lehetne befolyásuk. A STRUKTREFERENCIA változatban az előrejelzés időpontját követő széladatokat eleve kizárjuk a bemeneti csomópontokból, és így természetesen ezek a tervezettek szerint 0 % részesedéssel szerepelnek az előrejelzésekben.


Az ezt követő, $t=1..6$ h órák előrejelzéseinél azt tapasztalhatjuk (37.-42. ábra), hogy az ANN automatikusan felismeri, hogy a vízszint-előrejelzés időpontját követő széladatok nem befolyásolhatják jelentősen a vízszintet: a szélsébség részesedésének megugrása az előrejelzés órájával szinkronban csúszik el a 17. csomóponttól balra. Mivel a nagyobb időtávú előrejelzések szempontjából egyre kevésbé fontos az utolsó $t=-1$ h vízszint, ezért ennek a részesedése folyamatosan csökken az előrejelzéssel egyidejű szélsébség javára (frissebb információ, relatív szoros keresztkorrelációs tartalom mellett). A $t=6$ h előrejelzésnél láthatjuk, hogy a legdominánsabb bemeneti adattá a $t=6$ h szélsébsége válik, míg $t=0\dots5$ h előrejelzésnél a $t=-1$ h vízszint volt az.

Ezen eredmények tükrében meg lehet erősíteni, hogy a hibrid hálózat alkalmazása adja a legpontosabb, helyes tartalommal bíró előrejelzést.




36. ábra Bemenő csomópontok részesedése a $t=0$ h-ra (azaz az első órára) előrejelzett vízszintekben az 1. véletlen pontban

Bejövő csomópontok részesedése a 2 órás előrejelzett vízszintekben




37. ábra Bemenő csomópontok részesedése a $t=1$ h-ra előrejelzett vízszintekben az 1. véletlen pontban

Bejövő csomópontok részesedése a 3 órás előrejelzett vízszintekben




38. ábra Bemenő csomópontok részesedése a $t=2$ h-ra előrejelzett vízszintekben az 1. véletlen pontban

Bejövő csomópontok részesedése a 4 órás előrejelzett vízszintekben




39. ábra Bemenő csomópontok részesedése a $t=3$ h-ra előrejelzett vízszintekben az 1. véletlen pontban

Bejövő csomópontok részesedése az 5 órás előrejelzett vízszintekben




40. ábra Bemenő csomópontok részesedése a $t=4$ h-ra előrejelzett vízszintekben az 1. véletlen pontban

Bejövő csomópontok részesedése a 6 órás előrejelzett vízszintekben



41. ábra Bemenő csomópontok részesedése a $t=5$ h-ra előrejelzett vízszintekben az 1. véletlen pontban



42. ábra Bemenő csomópontok részesedése a $t=6$ h-ra (azaz a hetedik órára) előrejelzett vízszintekben az 1. véletlen pontban

8. Hétórás vízszint-előrejelzés készítése a Balatonra Siófoknál

Eljutottam oda, hogy az ANN előrejelzését mért széladatokkal a Balaton szabálytalan mederalakjára megvizsgáljam, így egy gyakorlati igényeket is kielégítő előrejelző eljárást leteszteljek.

A korábbi vizsgálataim megalapozták az ANN ehhez szükséges szerkezetét: a csomópontok és rejtett rétegek számát, a transzformációs függvényeket. A Balatoni Információs Rendszerből a 2009.06.06 – 2009.09.06 időszak hidrometeorológiai és vízrajzi adatsorai rendelkezésemre álltak, mint ahogyan azt a 2. fejezetben bemutattam. Emlékeztetőül, ezek a siófoki (16. ábra), keszthelyi és balatonszemési tóközepi szélsőségek, illetve a siófoki és a keszthelyi parti vízállások (43. ábra).


Előrejelzést ezek közül csak Siófokra készítik.

A munkámban lefektetett módszertant követve a feladatot a korrelációs függvények megszerkesztésével kezdtem. A 44. ábrán látható, hogy a legtöbb állapotváltozóval elég szoros (0,5-nél nagyobb) korrelációban van a siófoki vízállás. A siófoki vízállás és az egyéb állapotváltozók között megfigyelt korrelációs kapcsolat viszont nem feltétlenül jelent sok új információt (ehhez célszerű lenne megvizsgálni az állapotváltozók

közötti keresztkorrelációt is). A siófoki vízállás előrejelzésnél célom, hogy a korábbi módszertan továbbfejlesztéseként ne egyetlen pontbeli vízállást és egyetlen pontbeli szélsőértéket vonjak be az előrejelzésbe bemenő adatként, hanem több állomás vízszint- illetve szélsőérték-adatsorát is felhasználjam az információtartam maximalizálása érdekében. Ezek alapján, a korábbi módszertanhoz hasonlóan először $t=0$ h-ra készítettem előrejelzést a siófoki vízszintekre vonatkozóan, amelyekhez $t=-15 \dots -1$ h siófoki és keszthelyi vízállást vettem figyelembe, $t=-5 \dots 0$ h siófoki és balatonszemési szélsőértékkel (északi és keleti komponensek is). A keszthelyi szélsőértéket azért nem vettem be a bemeneti adatok közé, mert a siófoki medencétől távol van, és egyórás előrejelzéshez az információtartalmából nagy rész várhatóan benne van a keszthelyi vízállásban is.

A korábbi módszertanhoz hasonlóan redukálható a csomópontszám, ha ezt az alapváltozatot megtanítatom, majd az eredmények alapján kiveselek azokat a csomópontokat, amelyeknek kicsi a részesedése az előrejelzésben. Az alapváltozat eredményei alapján a $t=0$ h (azaz egyórás) előrejelzéshez érdemben (2%-nál nagyobb részesedéssel) a megelőző 7 óra siófoki és keszthelyi vízszintje járult hozzá, 1 óra megelőző és 1 óra jövőbeli ($t=-1$ ill. 0 h) siófoki szélsőértékkel. Itt már érzékeny volt a vízszint a keleti komponens mellett az északira is.

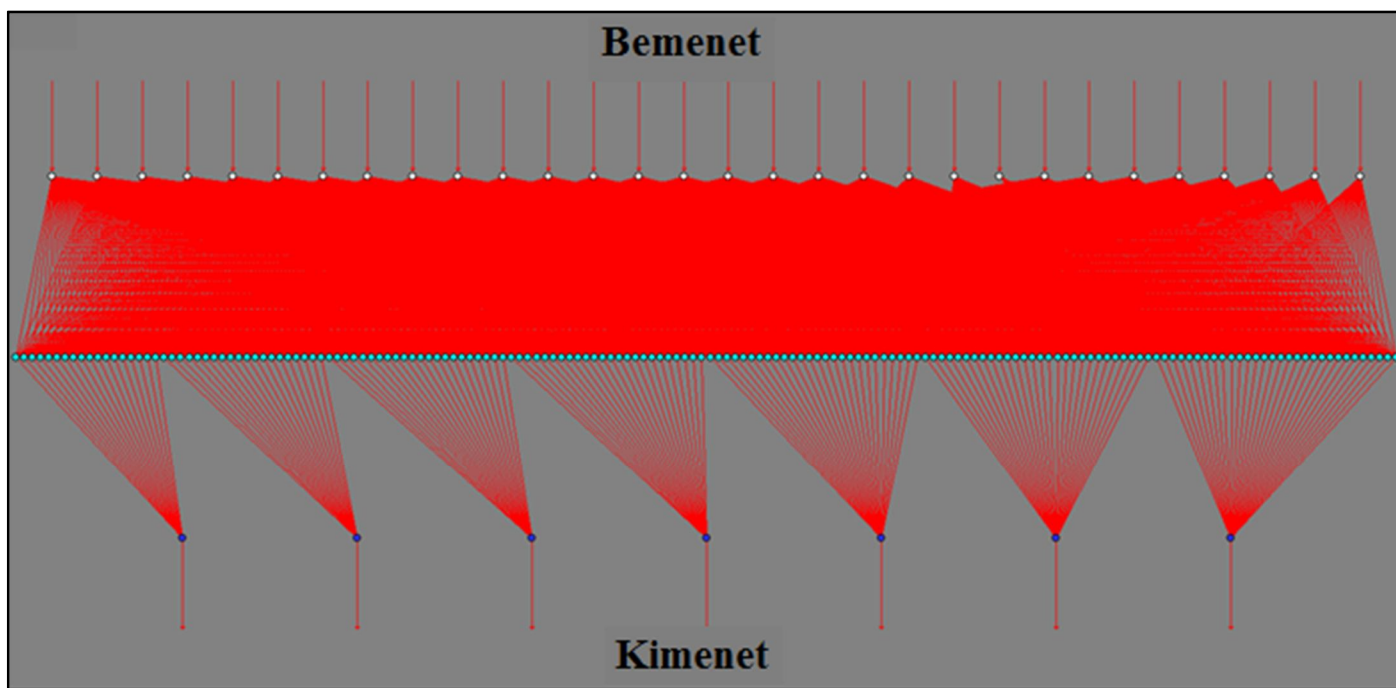
Ellenőrzésként elkészítettem a redukált csomópontú hálózatot, amellyel valóban hasonló pontosságú előrejelzést kaptam, mint a teljes hálózattal. A redukált csomópontú hálózat végül 18 bemeneti, 18 rejtett és 1 kimeneti csomópontot tartalmaz, ami kisebb, mint az alapváltozat, így gazdaságosabban tanítható.



43. ábra Mért siófoki és keszthelyi vízállások 2009.06.06 – 2009.09.06 között a siófoki vízmérce „0” pontjához viszonyítva (103,41 mBf)



44. ábra Korrelációs függvények a siófoki vízállás és egyéb, különböző állapotváltozók között



45. ábra SIÓFOK jelű hálózati modell a QNetben 7 órás előrejelzésnél

Miután megállapítottam, hogy a múltból milyen hosszú időszakot érdemes megadni az ANN-nek az egyórás előrejelzéssel, az eljárást kiegészítettem $t=0\dots6$ h vízállás-előrejelzésre. Ehhez tehát 6-6 újabb jövőbeli keleti és északi síófoki szélsébség komponenst kell megadni, 6 újabb előrejelzendő kimeneti vízállás csomóponttal. A rejtett réteget és a rétegek közötti kapcsolatot úgy szerkesztettem meg, hogy a jövőbelítés (előrejelzés időpontjához képest jövőbeli adat) lehetőségét letiltottam. A síófoki vízállás előrejelzéséhez nem használtam fel más helyre előrejelzett vízállást. Így összességében 30 bejövő, 168 rejtett és 7 kimeneti csomópontom van. A bemeneti réteg első 7 csomópontja a $t=-7\dots-1$ h síófoki vízszinteket, a következő 7 csomópont a $t=-7\dots-1$ h keszthelyi vízszinteket, az azt követő 8 csomópont a $t=-1\dots6$ h Síófoki keleti szélkomponenseket, az utolsó 8 csomópont pedig az északi szélkomponenseket reprezentálja. A hálózati rajz a 45. ábrán megismerhető.


A $t=0\dots6$ h előrejelzésnél, a korábbi módszertanhoz hasonlóan, több paraméter módosítását kipróbáltam homogén szigmoid és hibrid tangens hiperbolikus – szigmoid hálózatokon. A futtatások eredményeit szemlélve a következőkben a legjobb hálózat mutatom be, amelyik a homogén szigmoid hálózat lett. A korábbi tapasztalatoknak megfelelően a hibrid hálózatoknál ugyan kisebb hibaértékeket kaptam

össességében, mint a homogén hálózatoknál, de azok még inkább túl lettek tanítva (az igazoló halmazokon jelentősen nagyobb hibát kaptam, mint a tanuló halmazon). Ezért ebben az esetben a statisztikai mutatószámokat a tanuló és az igazoló halmazra külön is bemutatom.


A fentiek alapján a választott hálózatom paramétereit:

Hálózat neve	SIÓFOK
Rétegek száma	3
Input csomópontok száma	$30=7+7+(7+1)+(7+1)$
1. Rejtett réteg csomópontjainak száma	168
Transzformációs függvény	Sigmoid
Gráfszerk. Élkapcs. Bemenő és 1. Rejt. rétegek között	részleges
Kimenő csomópontok száma	7
Transzformációs függvény	Sigmoid
Gráfszerk. Élkapcs. 1. Rejt. És Kimenő rétegek között	részleges
Teszt esetek száma	495 (2195-az összes eset)-végéről
Iterációszám	70000
Tanulási ráta (ETA):	0.005000
Tehetlenség (ALPHA):	0.800000

8. táblázat Főbb futtatási és modell paraméterek a Siófoki $t=0\dots6$ órás vizállás-előrejelzésnél



46. ábra RMS hiba az iterációs lépés függvényében a tanuló halmazon a SIÓFOK modellben




47. ábra RMS hiba az iterációs lépés függvényében az ellenőrző halmazon a SIÓFOK modellben

Az RMS hiba alakulását a 46-47. ábrán látható, amelyről megállapítható, hogy a tanuló halmaz hibafüggvénye végig csökkenő trendet mutat, míg az ellenőrző halmazon kezdeti csökkenést követően nem változik a hiba. (Itt ismételten megjegyzem, hogy az iteráció kizárólag a tanuló halmazon igyekszik csökkenteni a mérés–előrejelzés hibáját. Az ellenőrző halmazon elért hiba pedig az iteráció következményeit nem befolyásolja, csak követhetővé teszi.)

Itt nem ábrázolt, hosszabb iterációk esetén a tanuló halmaz hibája tovább csökkent, míg az ellenőrző halmazé nőtt (túltanulás). Miután sikerült kiválasztani a lehető legpontosabb eredményt igazoló hálózatot, érdemes megvizsgálni a hiba burkolóinak alakulását időssal, illetve az előrejelzés időtávja szerint.

A 48/a ábrán, az előrejelzés hibáinak idősorán megállapítható, hogy a hiba jellege lényegesen nem változik a tanuló és az ellenőrző időszakban (ezeket az 1700. óra választja el), amely megerősíti egy optimális tanulási szint elérését. Az ábrát továbbvizsgálva megállapítható, hogy a hibaértékek zöme ± 2 cm-en belül található és a szélsőségesen nagy 4 cm-t meghaladó hibák csak szórványosan fordulnak elő.



48/a. ábra 7 órás siófoki vízállás-előrejelzés jellemző hibafüggvényei

Statistikai mutató típusa	Mérés [cm]	Előrejelzés hibastatisztikája [cm]							Halmaz típus
		1 órás előrejelzés	2 órás előrejelzés	3 órás előrejelzés	4 órás előrejelzés	5 órás előrejelzés	6 órás előrejelzés	7 órás előrejelzés	
max	118.080	6.58	8.37	6.66	9.87	10.04	10.01	9.72	Tanuló halmaz
min	78.160	-5.25	-6.18	-4.75	-4.87	-4.55	-5.16	-4.80	
átlag	98.052	-0.03	0.00	0.00	0.00	0.00	0.00	0.00	
szórás	4.899	0.63	0.83	1.03	1.12	1.11	1.10	1.07	
szum epi ²	-	679.13	1181.35	1811.15	2114.40	2089.33	2039.54	1955.30	
korreláció [-]	-	0.9922	0.9856	0.9774	0.9740	0.9743	0.9749	0.9761	
max	92.340	2.45	2.60	1.94	2.27	2.93	3.17	3.05	Ellenőrző halmaz
min	77.780	-2.63	-4.36	-5.43	-5.83	-4.81	-4.97	-4.28	
átlag	86.046	0.12	-0.15	-0.52	-0.67	-0.46	-0.31	-0.04	
szórás	2.778	0.62	0.78	0.95	1.08	1.09	1.09	1.09	
szum epi ²	-	195.28	308.65	577.20	794.02	698.25	636.24	589.97	
korreláció [-]	-	0.9777	0.9592	0.9383	0.9218	0.9178	0.9187	0.9182	


9. táblázat SIÓFOK modell hibastatisztikája 7 órás előrejelzésnél

A 9. táblázatot elemezve látható, hogy a hibaátlag a tanuló halmazon gyakorlatilag 0, tehát a modell nem torzít, míg az ellenőrző halmazon a modell átlagosan alulbecsül, de ennek a maximálisan 0,5 cm körüli értéke elfogadható.


A teljes négyzetes hiba az előrejelzést időtávjával eleinte az elvárásoknak megfelelően nő, azaz távolra pontatlanabbul tudunk előrejelezni (48/b ábra). Váratlan viszont az, hogy a 4. órán túl az előrejelzés hibája nem nő tovább. A hiba megtorpanását fizikai alapon nem tudom egyértelműen megmagyarázni. Gyanítható, hogy az első négy órában még nem csillapodtak le a $t=0$ h-t megelőző vízfelszín hullámai, és így az előrejelzés a vízállások adatait hasznosítani tudja. A negyedik órától pedig a vízállások fokozatosan függetlenné válnak a jóval korábbi vízállásoktól és így az ANN egyedül a széladatokra kénytelen támaszkodni. Másig lehetőség, hogy a jelenség a QNet hibaminimalizációs algoritmusának a következménye.

A vízállások szerepe a bemeneti adatokban egy fontos kérdés, ezért megvizsgálom a hiba változékonyságát is (49. ábra). Itt is megmutatkozik, hogy az első négy órában meredek emelkedés tapasztalható a szórásban a 0,6 cm-es értékről a 1,1 cm-es értékre, majd az azt követő órákban stagnálás figyelhető meg. Hasonló változás mutatkozik a célérték és az előrejelzés korrelációjában is (50. ábra).


Az megalapozottabb következtetésekhez érdemes a bemenő csomópontok részesedését megvizsgálni a különböző időtávú előrejelzésekből.



48/b. ábra Hiba négyzetösszeg változása az előrejelzés időtávja függvényében a Siófok modelleiben




49. ábra Hiba szórásának változása az előrejelzés időtávja függvényében a Siófok modellelben



50. ábra Méréshez viszonyított korreláció változása az előrejelzés időtávja függvényében a Siófok modellelben


Az 51-57. ábrákat megtekintve és összehasonlítva a 44. ábra korrelációs függvényeivel megállapítható, hogy az adott bemenő csomópontok részesezés diagramjai itt is tükrözik a korrelációs függvényeket. Az ábráról megállapítható az is, hogy a $t=0$ h előrejelzésnél legnagyobb arányban a megelőző óra vízállása játszik szerepet, a gerjesztő szélkomponensek hatása ezen az időtávon még nem túl nagy. Majd az időtáv növelésével a távolabbi múltból visszaható vízállás hatása csökken az előrejelzésben a szélkomponens súlyának javára.

Bejövő csomópontok részesedése az 1 órá előrejelzett vízszintekben




51. ábra Bejövő csomópontok részesedése a $t=0$ h előrejelzett vízszintekben Siófoknál (t_0 =aktuális)

Bejövő csomópontok részesedése a 2 órá előrejelzett vízszintekben



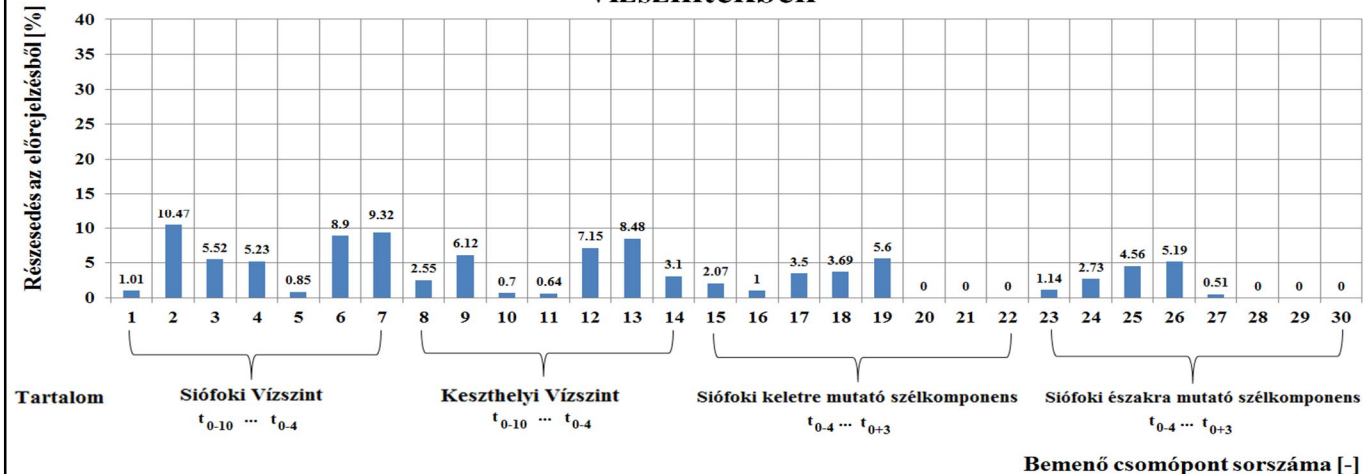
52. ábra Bejövő csomópontok részesedése a $t=1$ h előrejelzett vízszintekben Siófoknál (t_0 =aktuális)

Bejövő csomópontok részesedése a 3 órá előrejelzett vízszintekben




53. ábra Bejövő csomópontok részesedése a $t=2$ h előrejelzett vízszintekben Siófoknál (t_0 =aktuális)

Bejövő csomópontok részesedése a 4 órás előrejelzett vízszintekben



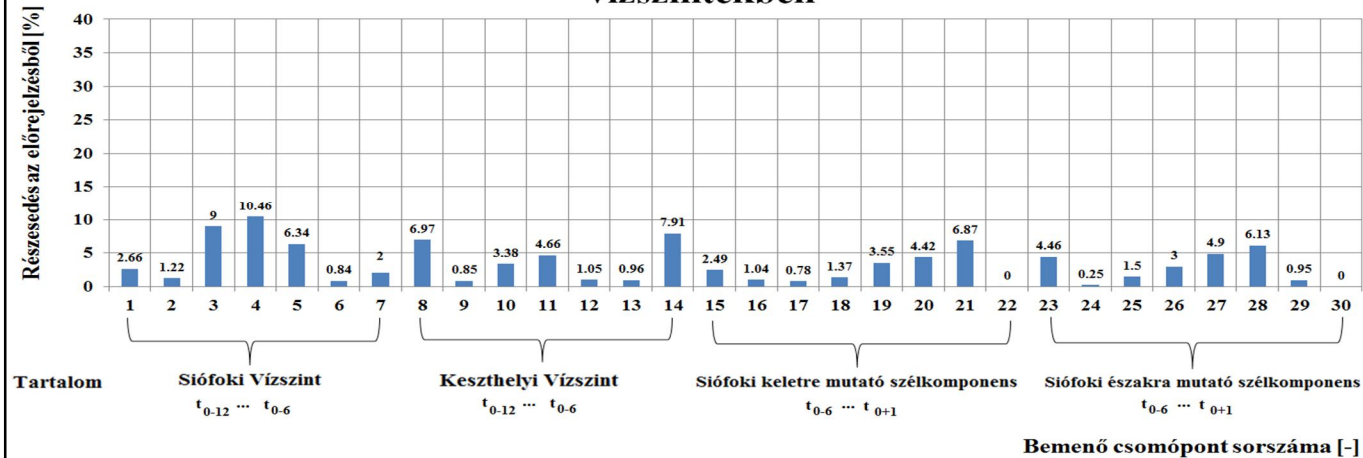
54. ábra Bejövő csomópontok részesedése a $t=3$ h előrejelzett vízszintekben Siófoknál (t_0 =aktuális)

Bejövő csomópontok részesedése az 5 órás előrejelzett vízszintekben




55. ábra Bejövő csomópontok részesedése a $t=4$ h előrejelzett vízszintekben Siófoknál (t_0 =aktuális)

Bejövő csomópontok részesedése a 6 órás előrejelzett vízszintekben



56. ábra Bejövő csomópontok részesedése $t=5$ h előrejelzett vízszintekben Siófoknál (t_0 =aktuális)

Bejövő csomópontok részesedése a 7 órás előrejelzett vízszintekben



57. ábra Bejövő csomópontok részesedése a $t=6$ h előrejelzett vízszintekben Siófoknál (t_0 =aktuális)

9. Összefoglaló

Dolgozatom fő célkitűzéseit eredményesen teljesítettem: a síófoki vízszintek alakulására egy megfelelően pontos, háromrétegű mesterséges neurális hálót építettem fel. Ehhez előzőleg egyszerűsített, idealizált tesztpéldákon megfelelő módszertant dolgoztam ki az ANN különböző paramétereinek az érzékenységvizsgálatához, az optimális szerkezet megállapításához.

A neurális háló bemeneti csomópontjaiban háromhavi órás szélsőértékeket és vízszinteket írtam elő, melyeket a BIR hálózaton mérték meg. A kimeneti rétegen pedig az egyidejűleg mért vízszinteket használtam fel $t=0,1,2\dots 6$ órás előrejelzés készítéséhez. A tanuló időszak és az ellenőrző időszak előrejelzésében a méréshez viszonyított korreláció, hibaszórás, hiba átlag közel azonos (kb 5%- on belül vannak a különbségek), azaz az ANN nem lett túltanítva.

A hiba statisztikája alapján azt találtam, hogy az első 4 óra előrejelzése minőségileg más (jobb), mint az utolsó 3 óráé, ami összefügg az előrejelzés kezdeti feltételeként adott vízállás és a peremfeltételeként adott szél befolyása arányának változásával, ahogy nő az előrejelzés időtávja.

Összességében a kapott eredményeket alkalmasnak vélem a gyakorlati alkalmazásra is. Ugyanakkor tekintettel kell lenni arra is, hogy a kb. kéthónapos tanítási időszakot meg lehetne hosszabbítani több évre is, ahhoz hogy a szélesebb körű alkalmazhatóságot biztosíthassuk. A neurális háló minőségének további javításához célszerű több mérési adatsort is alkalmazni, amelyek lehetőleg egymástól minél függetlenebbek, de az előrejelzéssel szoros korrelációs kapcsolatban vannak.

A jövőben érdemes lehet megvizsgálni azt is, hogy a szélsőértékek helyett a szélsőértékek négyzetét megadjuk meg bemeneti adatként, mivel a szél-csúsztatófeszültség és ezen keresztül a tófelszín kilendülése is durván az utóbbival lineáris összefüggésben van. Tehát egyfajta linearizáló „előfeldolgozással” akár pontosíthatjuk a neurális háló függvényközelítő képességét, valamint a korrelációs kapcsolatokat is

tisztábban láthatjuk. Amúgy a neurális hálók fő előnye az ARMA típusú eljárásokkal éppen az, hogy velük szemben alkalmassá tehetők a nemlineáris függvénykapcsolatok leírására is.

További kérdést is felvet a munkám: a neurális háló előrejelzése hogyan viszonyul a végeselem- ill. véges-térfogat alapú hidrodinamikai modellekkel elérhető előrejelzéshez? Pontosítható-e a hidrodinamikai modell eredménye azzal, hogy a hibájával megtanított neurális hálóval becsüljük meg a modell szükséges korrekcióját?

10. Hivatkozások

BIR 2012. Balatoni Információs Rendszer weblapja, <http://bir.webeye.hu/>

Sztobryn, M. 2003., *Forecast of storm surge by means of artificial neural network*, *Journal of Sea Research* 49 (2003) 317– 322

Kavehkar, S. ,Ghorbani, M. A., Khokhlov, V., Ashrafzadeh, A., Darbandi, S. 2011., *Exploiting Two Intelligent Models to Predict Water, Level: A field study of Urmia lake, Iran* , *International Journal of Civil and Environmental Engineering* 3:3 2011

Paláncz, B. 2011., *Mesterséges Intelligencia Építőmérnököknek*

QNet 2000, *Neural Network Modeling for Windows*, <http://qnetv2k.com>

Krámer, T.; Józsa, J. (2005): *An adaptively refined, finite-volume model of wind-induced currents in Lake Neusiedl. Periodica Polytechnica, Ser. Civil Engineering* 49(2), 111–136, www.pp.bme.hu/ci/index.html

Krámer, T. 2010, *Dxfproc program használati útmutatója*. BME Vízépítési és Vizgazdálkodási Tanszék

Jain, P., Deo, M. C., Latha, G., Rajendran, V. 2011 *Real time wave forecasting using wind time history and numerical model*, *Ocean Modelling* 36 (2011) 26–39