

Neurális hálók aszfalttechnológiai alkalmazása

KONCSOS TAMÁS ■ BME Vízi Közmű és Környezetmérnöki Tanszék ■ bonsalty@gmail.com

TÓTH CSABA ■ BME Út és Vasútépítési Tanszék ■ toth@uvt.bme.hu

Érkezett: 2012.03.25. ■ Received: 25.03.2012. <http://dx.doi.org/10.14382/epitoanyag-jsbcm.2012.6>

Asphalt technological application of the neural network

The article depicts a possible asphalt technological application of the neural network using the data of the numerous stiffness tests of three domestic asphalt mixtures. The results reinforce the preliminary expectations by which the MLP (Multilayer Perceptron) network built upon the tests results specified by indirect tensional tests is capable of prognosticating the stiffness very precisely in the trained range. Although the possible drawback of the method may be observed in its inexact extrapolating ability, it can be improved by the continuous development of the database furthermore managed having produced a combined map using the Kohonen map just as in this present work. The article verifies that the estimation of the stiffness of the mixtures made with the help of the neural network is a lot better than those applied at the traditional models, furthermore draws the attention to the fact that the superbness of the neural network lies exactly with their universality and the optional feature of the mixtures can be tested and prognosticated in the future with their help.


1. Az aszfaltkeverékek merevségének jelentősége

Sajnos ma sem állíthatjuk, hogy a hazai aszfaltreológiai kutatások a világ élvonalba tartoznának, azonban ennek fényében különösen örvendetes, hogy egy korábbi szakmai döntés nyomán az aszfaltkeverékek tervezési követelményeinek meghatározása vonatkozásában az empirikus előírásokkal szemben a fundamentális előírások kerültek rögzítésre. Ezen döntésnek köszönhetően azonban a teljesítményalapú követelmények és az ezekhez rendelt, elsősorban a keverékek fáradásával, illetve merevségével kapcsolatos vizsgálatok jelentősége is megnőtt.

Az EN 13108-20:2006 európai szabvány – ez elv szerint – az aszfaltkeverékek tulajdonságainak esetében megkülönbözteti vizsgálati módszereit, például:

- performance-related (leistungsbezogen): vízerzékenység, üzemanyag-állóság, maradó alakváltozással szembeni ellenállás kis, illetve nagy kerek nyomvályúvizsgáló vizsgálórendszer esetén,
- performance-based (leistungsbasierend): merevség, fáradás, maradó alakváltozással szembeni ellenállás triaxiális vizsgálat esetén.

Az 1. ábra a teljesítményelvű és teljesítményalapú vizsgálatok közötti finom különbség demonstrálására tesz kísérletet.



1. ábra A teljesítmény szintek illusztrációja (Tóth, 2006)
Fig. 1. Illustration of various levels of performance specifications (Tóth, 2006)

A teljesítményalapú aszfaltvizsgálatok kiemelt jelentőségével egyetértve a BME Út és Vasútépítési tanszékén – a rendelkezésre álló forrásokhoz mérten – jelentős kutatások folynak

Dr. TÓTH Csaba

Okl. építőmérnök, MBA, PhD. A Magyar Mérnöki Kamara és a Magyar Útügyi Társaság Útépítési Szakbizottság tagja, jelenleg az BME Út és Vasútépítési Tanszék adjunktusa. Korábban a Csongrád Megyei Állami Közútkezelő Kht., illetve az Állami Közúti Műszaki és Információs Kht. osztályvezetőjeként a magyar útügyi adminisztrációban dolgozott. Később a Strabag Konzern mérnökeként részt vett az épülő hazai országos közúthálózat minőségellenőrzésében, valamint a Konzern nemzetközi és hazai kutatásaiban. Közlekedési építőmérnöki szakértőként, tervezőként, illetve műszaki ellenőrként közreműködött számos burkolat-megerősítési projektben. Kutatási területe: hajlékony útpályaszerkezetek igénybevétele, méretezése, teherbíró-képessége, megerősítése. Publikációinak száma: több mint 30.

KONCSOS Tamás

Okl. építőmérnök, jelenleg a BME Vízi Közmű és Környezetmérnöki Tanszék PhD hallgatója. Korábban a GeneralCom-nál dolgozott programozói munkakörben, illetve a BME VKKT-val közösen folytatott WateRisk vízgazdálkodási döntéstámogató rendszer kiépítésében tevékenykedett. Az FVM megbízásában a LeoEpa hálózat szimulációs program tervezője, jelenleg számos hazai kutatási tevékenységben vesz részt. Kutatási tevékenységek: mesterséges intelligencia, lágy számítási módszerek alkalmazása a környezetmérnöki gyakorlatban, neurális hálózatok applikációja optimalizációs feladatok megoldására, szakértői rendszerek fejlesztése. Publikációinak száma: 6.

e területen, amelyek nyomán az elmúlt időszakban született értekezések már elsősorban az aszfaltkeverékek merevségével, illetve fáradási tulajdonságaival kapcsolatos kérdésekre is fókuszáltak. A téma aktualitását mutatja továbbá, hogy az aszfaltkeverékek merevsége kapcsán az elmúlt időszakban számos cikk is született. Többek között egy, az aszfaltkeverékek merevségének prognosztizálási lehetőségével kapcsolatos cikkben (Fi-Tóth, 2010) említésre került már a mesterséges neuronhálózatok (ANN, artificial neural network) alkalmazhatósága az aszfaltkeverékek merevségét becsülő modellek megalkotása sorában.


Az ANN elvét az emberi idegrendszer, az agy idegsejtjeinek működése ihlette, és noha az 1940-es évek végén kezdődő kutatások eredeti célja az emberi agyfunkciók szimulálására irányult, az ANN modelleket ma már például a statisztikai elemzések vagy az adatfeldolgozás területén is alkalmazzák, többnyire nem-lineáris folyamatok elemzésére. Ezek a modellek azonban elsősorban a mérési eredmények technikai feldolgozása során jelentenek segítséget, erre alapozva azonban különböző becslések kidolgozására is képesek.

Jelen cikkben korábbi kutatások (Fi et al, 2009) nyomán született adatbázis segítségével az ANN technika aszfalttechnológiai alkalmazhatóságát demonstráljuk. Felhívjuk azonban a figyelmet arra, hogy ezen elv alkalmazhatósága lényegesen sokoldalúbb, elég, ha csak azon modelleket említjük, amelyek az útpályaszerkezetek Falling Weight Deflectometerrel (FWD) mért behajlási teknőinek kiértékelésére készültek (Saltan et al, 2011), de akár egyszerű laboratóriumi vizsgálatok elemzésére, például Marshall stabilitás előrejelzésére alkalmas modellek is készíthetők (Ozgan, 2011).

2. Neurális hálók

A mesterséges neurális hálózatok alapjait Cajal teremtette meg 1909-ben, amikor a gerincesek tanulmányozása során észrevette, hogy az állatok agya nagyszámú összekötött sejtből áll, amiket neuronoknak nevezett. Azóta igazolódott, hogy ezek képezik az információfeldolgozás alapvető részegységeit. Felfedezték, hogy egy neuronnak vannak olyan ágai, amelyek begyűjtik az érkező ingereket, majd egy másik ágon, továbbítják az erre adott választ.

A neuronok egyszerűsített matematikai modelljét W. S. McCulloch és W. Pitts készítette el 1943-ban. A modellben minden egyes bemenethez rendelhető egy súly, majd a súlyozott bemenetek összege a neuron átviteli függvényén keresztül adja a kimenetet (2. ábra).



2. ábra A McCulloch-Pitts neuron (Abonyi, 2006)
Fig. 2. The McCulloch-Pitts neuron (Abonyi, 2006)

Ez az összefüggés könnyen algoritmizálható, a kapcsolat az (1) egyenlettel írható le.

$$y = f\left(\sum_{i=1}^n w_i \cdot x_i\right) \quad (1)$$


ahol:

- y: a neuron kimenete
- f(): átviteli függvény
- w_i: súlytényező
- x_i: a neuron bemenetei (független változók)

A neuron jel-transzformációs képessége speciális, többértékű logikai kapuként is értelmezhető. A súlytényezők megválasztásával a rendszer szűk korlátok között taníthatóvá válik, azaz adott kimeneti jelek állíthatók elő a bemeneti minták alapján. A neuronok összekapcsolásával olyan hálózatokhoz jutunk, melyek már összetett matematikai feladatok megoldására is alkalmasak (adattömörítés, asszociatív memória, rendezés, univerzális függvényközelítés).

Függvényapproximációs célokra a nem rekurrens mesterséges neuron hálózatok leggyakrabban alkalmazott változata az előrecsatolt, többrétegű háló: MLP (Multilayer Perceptron). Az MLP rétegelt, a réteg fogalma alatt esetünkben egy neuron halmazt értünk, melyekre érvényesek az alábbi megkötések: az összes réteg valamennyi neuronja az előtte és utána álló réteg minden neuronjával kapcsolatban áll, azonban a sejtek nem kapcsolódnak egymáshoz a saját rétegen belül. A bemeneti réteg annyi neuronból áll, ahány bemenő változónk van. Ezek tulajdonképpen jeltovábbítást végeznek a többi csomópont felé. A első rétegben található a rejtett neuronok, amelyek száma tetszőleges lehet. Ezeknek mind a bemenete, mind a kimenete másik csomóponthoz kapcsolódik. Itt folyik a tulajdonképpeni

adatfeldolgozás. Matematikailag bizonyított, hogy a kétrétegű MLP elvben bármely folytonos függvény közelítésére alkalmas. Azonban figyelembe véve azt a tényt, hogy a rendelkezésre álló információ mennyisége korlátos és a megoldandó feladat a komplexitás függvényében akár egyszerűbb, de összetett módszerekkel is megoldható, a kétrétegű háló, illetve az MLP topológia sok esetben helyettesítendő. A kimeneti rétegben annyi neuron van, ahány kimeneti változónk van. Ezek továbbítják az információt a külvilág felé. A 3. ábra egy többrétegű háló kialakítást szemléltet.



3. ábra A többrétegű neurális háló szerkezete (Abonyi, 2006)
Fig. 3. The structure of the multilayered neural network (Abonyi, 2006)

A teljes MLP hálózat a (2) egyenlettel írható le:

$$\hat{y} = w_0 + \sum_{i=1}^m w_i \left(w_{i0} + f\left(\sum_{j=1}^n w_{ij} \cdot x_j\right) \right) \quad (2)$$

ahol

- y: a hálózat kimenete (becsült függő változó)
- f(): átviteli függvény
- w_i: súlytényező
- x_j: a hálózat bemenetei (független változók)
- n: független változók száma
- m: neuronok száma a rejtett rétegben

A neurális hálózatot meg kell tanítani a probléma megoldására. Ez jellemzően azt jelenti, hogy valamilyen nemlineáris optimalizációs eljárással keressük azokat a súlytényezőket, amelyeknél a hálózat az adott regressziós feladatot jól megoldja.

Az MLP hálózatok legfontosabb tulajdonságai (Abonyi, 2006):

- univerzálisak, a legtöbb regressziós probléma esetén használhatók,
- az extrapolációs tulajdonsága megjósolhatatlan, ezért nagyon fontos hogy a tanítási minta lefedje mind a függő, mind a független változók teljes tartományát,
- megfelelő számú neuron esetén a regressziós modell pontossága jó,
- a neurális háló tanítása lassú, nagy körülmények között igyekezzünk gyorsítani, de a modell kiértékelése gyors,
- a kész hálózat nem interpretálható.

2. Az adatbázis

Egy korábbi kutatás keretében (Fi et al, 2009) a kőváz összetételének merevségre gyakorolt hatását vizsgáltuk három keverék esetén. A vizsgált keverékek típusa SMA 11 (F), AC 22 (F) és AC 22 (mF) volt, három-három különböző kővázal tervezve. A tervezett szemeloszlások úgy lettek meghatározva, hogy egy-egy, a korábbi hazai szabályozás szerinti alsó, illetve felső határgörbe szemeloszlásának, további egy pedig ezen két szemeloszlás átlagának feleljen meg. Emellett a különböző kővázal keverékek 3-3-féle kötőanyag-tartalommal lettek előállítva.


A merevségvizsgálatokat – négy különböző hőmérsékleten – indirekt húzóvizsgálattal (IT-CY) végeztük. Ez a vizsgálat ugyan alapvetően nem képes különböző terhelési szintek megvalósítására, korábbi kutatásaink alapján azonban azt tételeztük fel, hogy a felfutási idő változtatásával a frekvenciterhelés jól szimulálható. Ennek érdekében a vizsgálatokat – a szabvány által előírt 124 msec felfutási idő helyett – négy terhelési szinten: 60, 90, 120, 150 msec felfutási idővel végeztük.

Figyelembe véve az eltérő szemeloszlás, a különböző kötőanyag-tartalom, illetve terhelési idő és vizsgálati hőmérséklet miatt létrejött változatokat, a merevségvizsgálatok száma keverékenként 144 darab volt, azaz mindösszesen 432 darab merevségvizsgálati eredmény állt rendelkezésre. Az így előállított adatbázis megteremtette annak lehetőségét, hogy a neurális háló segítségével építsük egy merevség előrejelző modellt és vizsgáljuk annak pontosságát.

3. Aszfaltkeverék merevség becslő modell MLP hálóval

Az aszfaltkeverék-merevség előrejelző modell kiépítéséhez először be kell táplálni az input adatokat és az észlelt eredményeket. Minél több keverék-összetételt és a hozzátartozó mért merevségi adatokat táplálunk be egy ilyen rendszerbe, annál pontosabban súlyozódnak az egyes lehetséges összefüggések és annál pontosabb lesz a prognózis.

Az input adatok lehatárolásánál – hasonlóan a nemzetközi gyakorlathoz – a Witczak-féle modell struktúráját (NCHRP, 2004) használtuk a 4. ábrán láthatóak szerint.

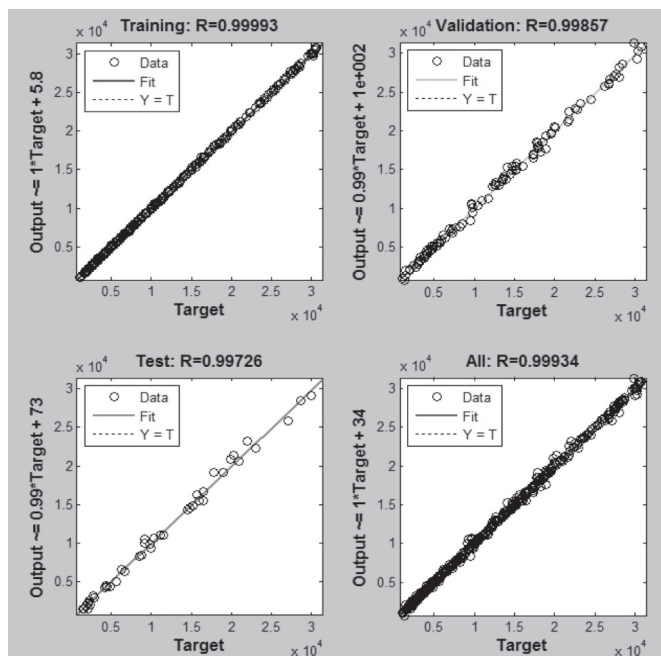


4. ábra Az alkalmazott MLP háló szerkezete
Fig. 4. The structure of the MLP network applied

A nemzetközi gyakorlathoz hasonlóan mi is azt tételeztük fel, hogy a vizsgálati eredményeket 8 paraméter elegendően pontosan határozza meg. A háló készítés során azonban az angolszász szitaméretet a hazai gyakorlatnak megfelelően aktualizáltuk, illetve a terhelési időt nem frekvenciában, hanem az IT-CY vizsgálat felfutási idejében adtuk meg. Továbbá a 20 °C-on nehézkesen meghatározható bitumen viszkozitás értékeket nem mértük, hanem penetráció mérés alapján becsültük. Mint az a 4. ábrán látható, a háló input adatai az alábbiak voltak:

- szemeloszlási görbe négy paramétere (p_i),
- V_a : szabadhézag-tartalom,
- V_{beff} : kötőanyag-tartalom,
- t : terhelési idő,
- η : kötőanyag viszkozitás (penetrációs érték alapján becsült).

Az így felépített MLP hálót a rendelkezésre álló mérési adatbázist kettéosztva, annak 300 mérési eredményének segítségével „tanítottuk be”. Az adatbázisunk második részével, azaz 132 darab mérési eredményével a háló pontosságát vizsgáltuk, validáltuk. A betanító és a validáló futtatások eredményeit összevetve a mérési adatokkal az 5. ábrán látható eredményeket kaptunk.



5. ábra Az előzetesen kapott eredmények statisztikai mutatói
Fig. 5. The statistical indexes of the preliminary results

A validált adatok alapján a korrelációs együttható magas értéke – megegyezően a nemzetközi eredményekkel – egyhez közelít, ami korábbi, hagyományos merevség-előrejelző modellekhez képest lényegesen pontosabb.


4. Az eredmények finomítása: a Kohonen háló

A háló tesztelése és az eredmények részletesebb tanulmányozása során azonban azt a következményt tapasztaltuk, hogy a háló merevség-előrejelző pontossága, ha eltérünk a tanításkor használt összetételi paraméterektől, romlik. A validációra kapott jó eredmény azzal magyarázható, hogy az ellenőrzés nem terjedt ki a szemeloszlási görbék kapcsolatának feltárására, a validált

minták ugyanis ugyanarra a 6 szemeloszlási görbére estek, mint a tanítási minták, azaz a neurális háló csak interpolációs feladatot oldott meg. Ez egy várt következmény, lévén a fentiekben a hálók legfontosabb tulajdonságai között megemlítettük az extrapolációs hibát. Ez a hiba természetesen a jövőben az adatbázis fejlesztésével folyamatosan javítható, arra kell törekednünk, hogy a tanítási minta minél teljesebb körben lefedje mind a függő, mind a független változók teljes tartományát.

Jelen esetben azonban szemeloszlási görbe kisebb változtatása is a neurális háló pontatlan előrejelzéséhez vezethet. Az extrapolációs hibák kiküszöbölése osztályozási módszerrel valószínűsíthető meg. Az alapötletünk, hogy a különböző adalékok a szemeloszlási görbéjük karakterisztikáját tekintve besorolhatók az általunk definiált szemeloszlási görbék egyikéhez. A feladat vektor-klaszterezéssel végezhető el, mely egy speciális, második neurális hálózat alkalmazásának szükségességét veti fel. A célunk tehát az n -dimenziós ($n > 2$) input minták egy kisebb dimenziós kimeneti réteg egy-egy elemére leképezni úgy, hogy a kívánt leképezés a bemeneti tér topológiai tulajdonságát megőrizze. Ugyanezt a logikai elvet követi az agy, „térbeli fogalmak” pl. hang, szag, vizuális és egyéb információk jelentéstartalmi szétválasztásánál, asszociációjánál.

A klaszterezést a Kohonen háló alkalmazásával értük el. Az önszervező térkép méretét 4×4 -esnek definiáltuk, mozgásteret engedve korlátozott extrapolációra (6. ábra).



6. ábra A kombinált neuronhálózat vázlatos rajza
Fig. 6. The rough sketch of the combined neuron network

A betanított Kohonen háló bármely szemeloszlási görbét egy-egy koordinátával párosított, így a bemenetek száma 2-vel csökkent. A görbék alapján az előállított koordinátákat felhasználva és a másik négy paraméterrel kombinálva az MLP korábbi extrapolációs hibája drasztikusan lecsökkent.

5. Összefoglalás

A neurális hálók aszfalttechnológiai alkalmazásának egyik lehetőségét három hazai aszfaltkeverék nagyszámú merevség vizsgálati adatsorát felhasználva mutattuk be. Igazoltuk, hogy az IT-CY

vizsgálati eredményekre épített MLP háló a betanított tartományban nagy pontosságú merevség előrejelzésre képes, és hátránya ugyan a pontatlan extrapolációs képességében tetten érhető, ez az adatbázis folyamatos fejlesztésével folyamatosan javítható.

Átmeneti megoldásként a Kohonen-háló felhasználásával létrehoztunk egy olyan kombinált hálót, amely ezen extrapolációs hibákat jelentős mértékben képes csökkenteni, így a modell a járatos hazai keverékek esetén képes – a technológiaiailag elképzelhető – összes összetétel esetén merevség-előrejelzésre.

Jelen cikkben ugyan a keverékek merevségének az összetétel alapján történő prognosztizálhatóságára helyeztük a hangsúlyt, de természetesen a neurális hálók nagyszerűsége éppen univerzalitásukban rejlik, segítségükkel a keverékek tetszőleges jellemzője vizsgálható, előre jelezhető. Ennek fényében az aszfaltgyártás során az eddig nem vizsgált input-output adatok közötti kapcsolatok vizsgálatában minden érdeklődő számára nagy segítséget jelenthet.

Kutatásunk további célja lehet a genetikus programozás adta lehetőségek felhasználása aszfalt keverékek jellemzőinek vizsgálatánál. A genetikus programozás az evolúció biológiában ismert szelekciós elvet alkalmazza az emberi beavatkozás nélküli tervezéshez. Használatuk előnye abban mutatkozik, hogy a neurális háló fekete doboz jellegű megoldásaival ellentétben könnyen interpretálható modellek jönnek létre, így a kapott válasz egyenletek formájában is megadhatók.

Felhasznált irodalom

- [1] Tóth Csaba: *A teljesítményi szabályozás nyújtotta többlet lehetőségek az útépitésben*, X. Nemzetközi Építéstudományi Konferencia, Csíksomlyó, 2006. június. Kiadó: Erdélyi Magyar Műszaki Tudományos Társaság. Szerkesztő: Köllő Gábor. ISBN (10) 973-7840-13-5, pp 331–336.
- [2] Dr. habil Fi I. – Tóth Cs.: *A szemeloszlás-változás aszfaltkeverék merevségre gyakorolt hatásának prognosztizálhatósága*. Közlekedésépítési Szemle, 60. évf. 2010/12. pp 24 – 31.
- [3] M. Saltan et al: *Backcalculation of pavement layer moduli and Poisson's ratio using data mining*. Expert Systems with Applications, Volume 38, Issue 3, March 2011, Pages 2600-2608
- [4] E. Ozgan: *Artificial neural network based modelling of the Marshall Stability of asphalt concrete*. Expert Systems with Applications Volume 38, Issue 5, May 2011, Pages 6025-6030
- [5] Dr. habil Fi, I. – Pethő, L. – Bocz, P. – Tóth, Cs.: *Aszfaltkeverékek teljesítményének vizsgálata*. KKK kutatási program, megrendelő: Közlekedésfejlesztési Koordinációs Központ. (2009)
- [6] National Cooperative Highway Research Program: *Guide for Mechanistic-Empirical Design of New and Rehabilitated Pavement Structures*. NCHRP 1-37-A: 2004
- [7] Dr. Abonyi J. (szerk): *Adatbányászat a hatékonyság eszköze*. 2006

Ref.: <http://dx.doi.org/10.14382/epitoanyag-jsbcm.2012.6>

Koncso Tamás – Tóth Csaba: *Neurális hálók aszfalttechnológiai alkalmazása*. Építőanyag, 64. évf. 1–2. szám (2012), 30–33. p.

IPARI GÁZOK KATALÓGUSA – AZ ONLINE TUDÁSTÁR

A gázok előállításával, szállításával, tárolásával és felhasználásával kapcsolatos legfontosabb információkat 216 oldalban összefoglaló Ipari Gázok Katalógusa már a www.messer.hu oldalon, elektronikus formában is elérhető. A gázok részletes adatain és az azokkal kapcsolatos általános tudnivalókon kívül a katalógus beszámol a

főbb előállítási módszerek alapjairól, a szállítási–tárolási–ellátási formák és eszközök részleteitől, a gázellátó és alkalmazástechnikai rendszerek adatairól, valamint a gázok helyes kezeléséhez szükséges biztonságtechnikai ismeretekről. Az e-katalógus elsődleges célja, hogy segítséget nyújtson vevőinknek az ipari gázok célszerű és gazdaságos kiválasztásához, vásárlásához, kezeléséhez és felhasználásához.

http://messer.hu/Infotar/Ipari_Gazok_Katalogusa