

Primjena tehnika mekog računalstva za predviđanje svojstva zrakopropusnosti tkanina

Prof.dr.sc. **Sevda Altaş**, dipl.ing.
Ege University Emel Akın Vocational Training School, Textile Program
Ege University Campus, Bornova
İzmir, Turska
e-mail: sevda.altas@ege.edu.tr
Prispjelo 20.12.2016.

UDK 677.017.622
Izvorni znanstveni rad

Zrakopropusnost tkanine je mjerilo brzine protoka zraka kroz tkaninu kod zadanog tlaka. Ona je vrlo značajna za svojstva udobnosti tkanina za izradu odjeće. Svrha istraživanja je primjena simulacije neizrazite logike i umjetne neuronske mreže za procjenu zrakopropusnosti lanenih tkanina. Za tu svrhu upotrijebljeno je 11 različitih lanenih tkanina i njihova osnovna fizikalna svojstva koja su ocijenjena: duljinska masa pređe, koeficijent uvijanja, površinska masa tkanine, gustoća tkanine i svojstvo propusnosti zraka. Svojstvo zrakopropusnosti lanenih tkanina predviđeno je upotrebom modela neizrazite logike (FL) i umjetne neuronske mreže (ANN) pomoću parametara koji djeluju na propusnost zraka prema literaturi. Predviđanja metoda ANN i FL uspoređena su s eksperimentalnim rezultatima. Prema rezultatima uočeno je da modeli ANN i FL daju izlazne rezultate koji su bliži eksperimentalnim rezultatima. Međutim, ustanovljeno je da je uspješnost procjene metode ANN bolja nego kod modela FL.

Ključne riječi: propusnost zraka, lanena tkanina, tehnike mekog računalstva, neizrazita logika (FL), umjetna neuronska mreža (ANN)

1. Uvod

Zrakopropusnost je značajno svojstvo jer utječe na svojstva zadržavanja topline, zaštite od vjetra, sposobnost tzv. disanja itd. tkanina, odnosno materijala koje se upotrebljavaju za izradu odjeće. Mjeri se kao volumen zraka u litrama koji prolazi kroz specifičnu površinu tkanine u minuti kod razlike tlaka.

Postoji velik broj radova o ispitivanju odnosa između zrakopropusnosti i strukturnih svojstava tkanina (materijala). Parametri koji utječu na zrakopropusnost tekstilnih materijala mogu se svrstati u tri temeljne skupine: 1) fizikalna svojstva vlakna, 2)

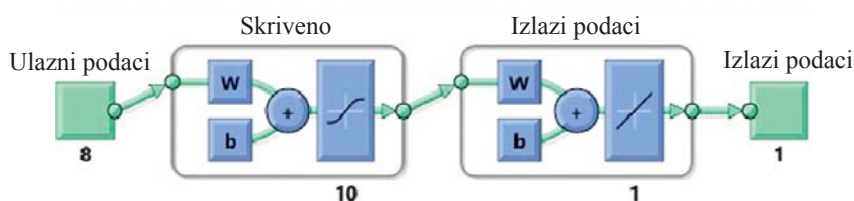
svojstva pređe i 3) konstrukcija tkanine. Ovi parametri utječu na veličinu i broj pora što je direktno povezano sa svojstvom zrakopropusnosti [1-5]. Tekstilne tkanine u svojoj strukturi imaju pore između vlakana i između pređa. Veličina pora je povezana s fizikalnim svojstvima vlakna kao što su finoća i oblik, te ti parametri utječu na zrakopropusnost od njih načinjenih tekstilnih materijala [3]. Sposobnost blokiranja prolaska zraka ili omogućavanje prolaska zraka kroz tkaninu ovisi i o konstrukciji, geometriji, debljini i poroznosti materijala. Povećanjem poroznosti i smanjenjem debljine, povećava se zrakopropu-

snost [6]. Također i gustoća tkanine kao parametar strukture ima značajan utjecaj na zrakopropusnost. Povećanjem gustoće tkanine (ili nekog drugog tekstilnog materijala), zrakopropusnost se smanjuje. Svojstva pređe kao duljinska masa i uvijitost su druga dva važna parametra koji određuju zrakopropusnost. Povećanjem duljinske mase, struktura pređe je kompaktnija te se povećava zrakopropusnost, ali i kod smanjenja duljinske mase pređe dolazi do povećanja zrakopropusnosti [7].

Tehnike mekog računalstva su važno sredstvo za predviđanje i modeliranje podataka i koriste se u različitim po-

Tab.1 Izmjereni parametri za ocjenu ponašanja zrakopropusnosti lanenih tkanina

Br. uzorka tkanine	Duljinska masa pređe (tex)		Uvojitost pređe (uvoja/m)		Gustoća tkanine u smjeru osnove (br. niti /cm)	Gustoća tkanine u smjeru potke (br. niti /cm)	Debljina (mm)	Površinska masa (g/cm ²)	Zrakopropusnost (mm/s)
	Osnova	Potka	Osnova	Potka					
1	27,60	26,97	625,1	633,2	23,4	18,8	0,29	123,7	1031,2
2	29,83	31,09	503,4	549,1	20,8	18,6	0,35	128,6	927,1
3	55,72	62,18	529,8	490,7	18,4	14,8	0,44	194,1	745,5
4	47,63	48,82	475,2	506,6	18,4	16,8	0,35	159,5	955,7
5	98,44	62,18	479,3	466,1	15,6	12,2	0,60	235,3	451,8
6	21,96	26,49	623,3	619,7	26,4	20,8	0,26	114,1	1125
7	44,75	43,75	469,0	465,6	19,8	18,2	0,37	167,4	847,9
8	56,79	60,89	457,2	443,3	18,0	14,4	0,43	193,9	797,4
9	37,62	36,02	546,5	561,6	19,8	18,0	0,36	158,3	942,3
10	54,19	54,19	457,5	436,0	18,6	14,2	0,44	208,3	643,7
11	66,37	67,89	566,8	582,7	18,2	14,4	0,51	225,7	528,8



Sl.1 Model ANN za predviđanje zrakopropusnosti

dručjima primjene [8]. U inženjerstvu tkanine koristili su se različiti računalni alati: metoda konačnih elemenata (Finite Element Method – FEM), umjetne neuronske mreže (Artificial Neural Networks – ANN), neizrazita logika (Fuzzy Logic – FL) i genetički algoritam (GA) kako bi se predstavile tkanine u računalnom okruženju i predvidjela njihova konačna svojstva [9].

ANN je važan alat za predviđanje i modeliranje podataka koji može vrednovati svaki odnos ulaznih i izlaznih podataka [10]. Matusiak je koristio ANN za predviđanje svojstva zrakopropusnosti za 106 varijanti pamučnih tkanina različitog veza i kompaktnosti. Rezultati ispitivanja su potvrdili dobru kvalitetu predviđanja zrakopropusnosti pomoću umjetnih neuronskih mreža [11]. Cay je ispitivao 30 različitih tkanina određenih gustoća potke i osnove. U radu se navodi da je greška predviđanja neuronske mreže 5 puta manja nego odgovarajuća greška dobivena višestrukom linearnom regresijom koja je

primijenjena za iste podatke [12]. Militkey i sur. uveli su neuronske mreže s racionalnom baznom funkcijom (RFB) te su raspravljene prednosti racionalne bazne funkcije u usporedbi s klasičnim neuronskim mrežama. Opisuje se strategija optimalnih brojeva racionalne bazne funkcije [13]. Nassif je usporedio stupanj procjene regresije i ANN. Rezultati tog rada otkrili su da je ANN bolji od regresijskog modela predviđanja svojstava tkanine [14]. Tokarska je predložio da bi prvi korak u procjeni modela, koji je dobiven u obliku umjetne neuronske mreže, trebala biti analiza osjetljivosti ulaznih podataka neuronske mreže. Na taj način konstruirani neuronski model svojstava tkanine daje dobar opis utjecaja strukturnih parametara plošnih tekstilnih proizvoda [15].

Neizraziti sustavi su temeljeni na znanju ili na pravilima. Glavni dio neizrazitog sustava je osnova znanja koja se sastoji od neizrazitih pravila uvjetne naredbe (AKO-ONDA). Metoda FL može se upotrijebiti za sva

ispitivanja provedena na području tekstila. Ovom metodom mogu se modelirati ponašanja kompleksnog sustava primjenom jednostavnih logičkih lingvističkih pravila [10]. U mnogim radovima koristi se ova metoda za parametre kvalitete pređa i tkanina u tekstilnoj industriji. Dayik i Yilmaz odredili su utjecaje dužine, finoće i čvrstoće vlakna na piling pamučnih vlakana pomoću metode neizrazite logike [16]. Neizrazita logika se također koristila za predviđanje mogućnosti pređenja i čvrstoće pređe pomoću pravila uvjetne naredbe – AKO-ONDA. Ustanovljeno je da je točnost metoda predviđanja bila dobra [17]. U istraživanju koje su proveli Park i sur. neizrazita logika i neuronske mreže korištene su za vrednovanje ukupnih vrijednosti opipa pletiva i rezultati su uspoređeni sa subjektivnim ispitivanjem. Navodi se da su neizrazita logika i umjetne neuronske mreže korisni alati za predviđanje ukupnih vrijednosti opipa pletiva i bolje odgovaraju rezultatima objektivnog ispitivanja nego kod sustava KES-FB [18]. Kılıç je koristio postupke analize slike i neizrazite logike u svom radu za određivanje koeficijenta pada tkanina za odijela, koje su izrađene od pređe od 100% češljanog vunenog vlakna te je ustanovljeno da su rezultati neizrazite logike bliži konvencionalnoj metodi po Cusicku [19]. Hussain i sur.

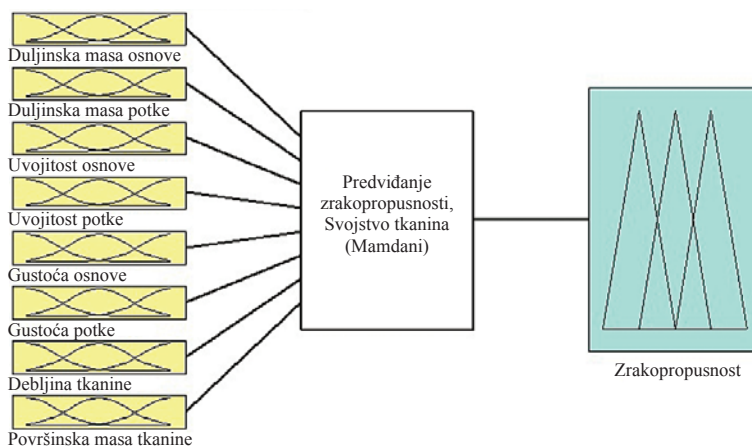
Tab.2 Usporedba eksperimentalnih rezultata, izlaznih vrijednosti dobivenih modelom umjetne neuronske mreže (ANN) i izlaznih defazificiranih (FL) vrijednosti zrakopropusnosti

Br. uzorka tkanine	1	2	3	4	5	6	7	8	9	10	11
Eksperimentalni rezultati	1031,2	927,1	745,5	955,7	451,8	1125	847,9	797,4	942,3	643,7	528,8
ANN izlazne vrijednosti	1067	919	748	956	457	1120	856	793	935	612	535
Razlika između eksp. i ANN vrijednosti (%)	3,47	-0,87	0,34	0,03	1,15	-0,44	0,96	-0,55	-0,77	3,47	-0,87
Defazificirane izlazne vrijednosti	1050	957	710	862	506	1080	855	742	938	736	535
Razlika između eksp. i FL vrijednosti (%)	1,82	3,23	-4,76	-9,80	12,00	-4,00	0,84	-6,95	-0,46	14,34	1,17

uspoređivali su modele ANN i sustava prilagodljivog neuro neizrazitog sustava zaključivanja (ANFIS) s eksperimentalnim podacima za predviđanje kuta oporavka tkanina od mješavine PES/pamuka. Prema rezultatima ispitivanja, predviđanja ANN su bolja nego predviđanja ANFIS [20]. U prošlosti su provedena su razna istraživanja koja su bila usredotočena na modeliranje zrakopropusnosti modelima temeljenima na umjetnim neuronskim mrežama (ANN). Međutim, dosad nije bilo upotrijebljeno modeliranje zrakopropusnosti neizrazitom logikom (FL). Ovo ispitivanje uključuje modele ANN i FL za ocjenu svojstva zrakopropusnosti tkanina.

2. Materijali i postupci

Materijal za provedbu ovog istraživanja bilo je 11 vrsta tkanina platnenog veza od 100 % lanenih vlakana. Tkanine su nabavljene od različitih proizvođača. Za ocjenu zrakopropusnosti lanenih tkanina određeni su parametri pređe i tkanine koji utječu na zrakopropusnost. Izmjereni su: duljinska masa pređe (tex), uvijitost (br. uvoja/m), gustoća tkanine u smjeru potke (br. potkinih niti/cm) i u smjeru osnove (br. osnovinih niti/cm), površinska masa (g/cm²) i debljina (mm). Duljinska masa osnove i potke za uzorke tkanine određene su prema ISO 7211-5:1984. Uvojitost pređa osnove i potke određene su prema ISO 7211-4:1984, a gustoća tkanine u smjeru osnove i potke određene su prema ISO 7211-2 (1984). Debljina uzoraka tkanine izmjerena je digitalnim uređajem za mjerenje debljine SDL ATLAS M034A prema ISO



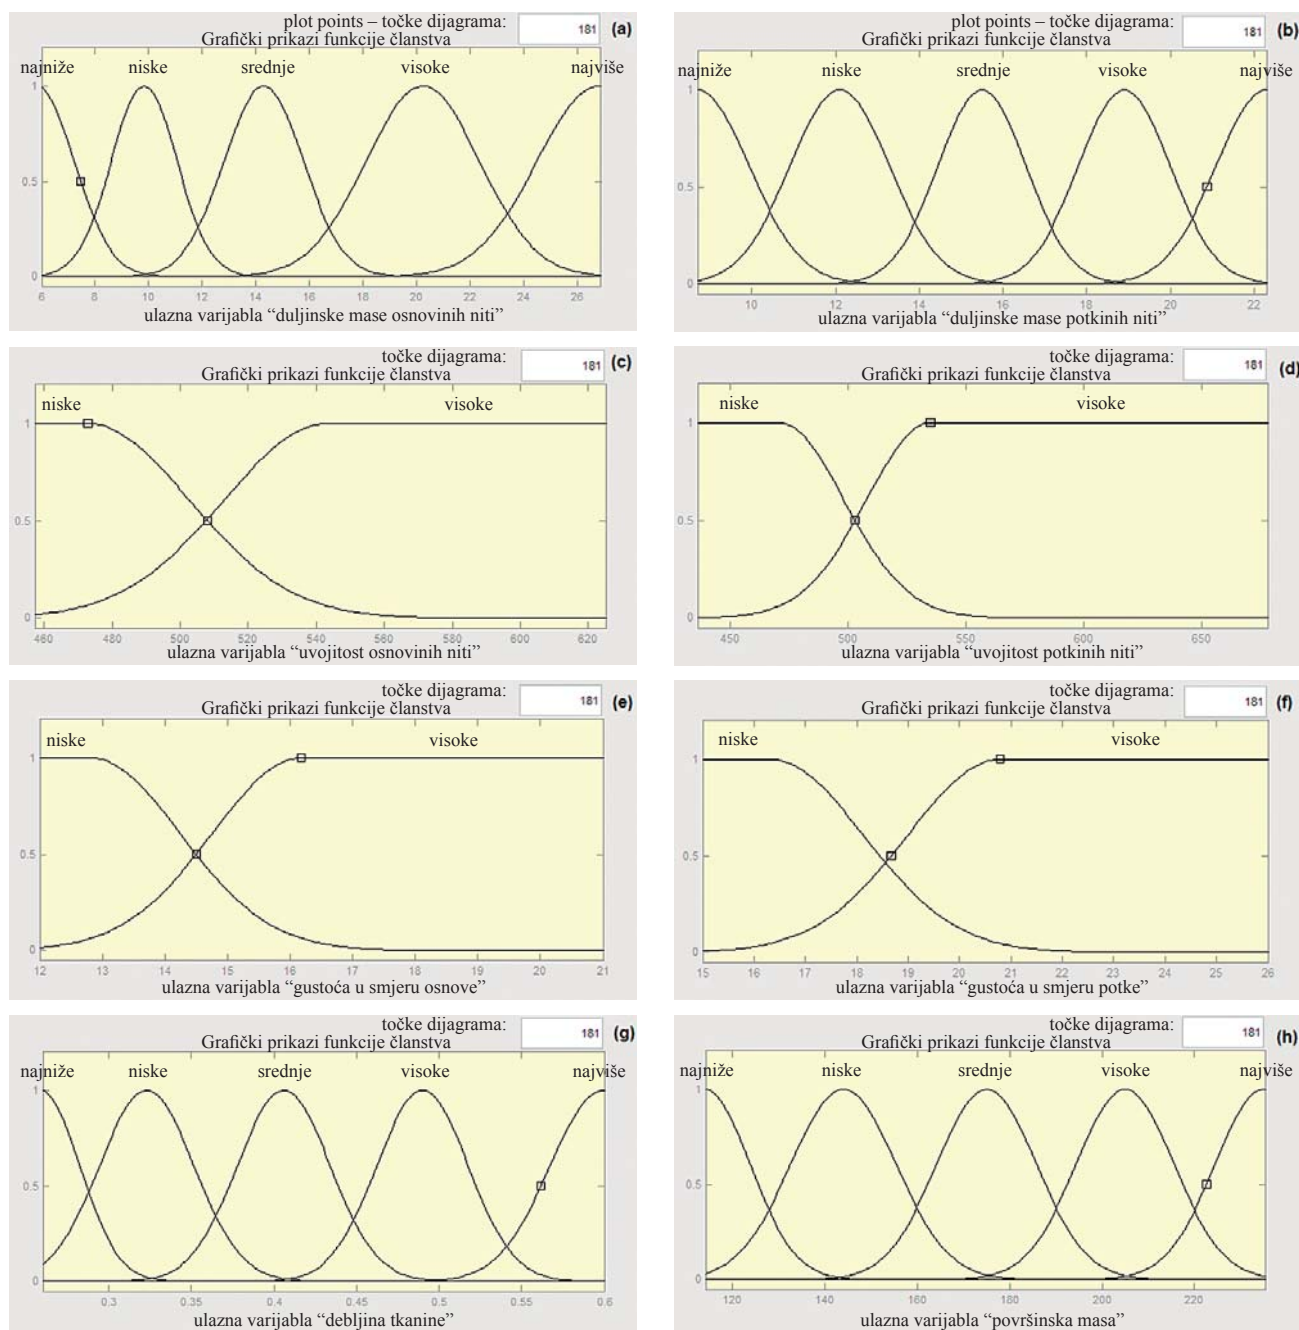
Sl.2 Model FL za predviđanje zrakopropusnosti lanenih tkanina

5084. Zrakopropusnost (mm/s) ispitana je uređajem za ispitivanje zrakopropusnosti Textest FX 3300 prema ISO 9237:1995. Sva mjerenja pređa i tkanina provedena su u standardnim uvjetima (20 ± 2 °C, 65 ± 4 % relativne vlažnosti).

Modeli ANN i FL su korišteni za predviđanje zrakopropusnosti. Izlazni podaci dobiveni modelima ANN i FL uspoređeni su s eksperimentalnim rezultatima zrakopropusnosti kako bi se odredio najbolji postupak predviđanja.

Za dobivanje modela ANN korišten je Neural Network Toolbox programskog paketa MATLAB i izrađen je model ANN za predviđanje zrakopropusnosti. Konstruiran je model ANN s troslojnim i unaprijednim algoritmom s povratnim rasprostiranjem greške koji ima sigmoidalnu prijenosnu funkciju u skrivenom sloju i linearnu prijenosnu funkciju u izlaznom sloju. Određivanje optimalnog broja neurona skrivenog sloja je vrlo važno za točno predviđanje parametra pomoću ANN, a taj broj

može biti dvaput veći nego ulazni ili izlazni neuroni [21]. Općenito, broj skrivenih neurona se određuje proizvoljno prema iskustvu [22, 23]. U ovom istraživanju broj skrivenih neurona za model ANN određen je nakon ispitivanja kako bi se dobili najbolji rezultati za predviđanje i izabrano je 10 skrivenih neurona. Podaci za umjeravanje i potvrđivanje modela mreže dobiveni su iz eksperimentalnog ispitivanja. Kod istraživanja eksperimentalno su određeni: duljinska masa pređe, uvojitost, gustoća u smjeru osnove, gustoća u smjeru potke, površinska masa, debljina i zrakopropusnost 11 različitih tkanina. Ukupno je dobiveno 110 izmjerenih podataka za svaki pojedinačni parametar. Za model ANN zrakopropusnost je korištena kao ciljna varijabilna vrijednost, ostale eksperimentalne vrijednosti su korištene kao ulazne varijable. Vrijednosti ulaznih varijabli nisu skalirane od 0 do 1. Kod modela ANN 70 % ovih vrijednosti korišteno je za učenje, 15 % za potvrđivanje i 15 % za ispitivanje.



Sl.3 Funkcije članstva ulaznih varijabli: (a) duljinske mase osnovinih niti, (b) duljinske mase potkinih niti, (c) uvojitosti osnovinih niti, (d) uvojitosti potkinih niti, (e) gustoća tkanine u smjeru osnove, (f) gustoća tkanine u smjeru potke, (g) debljina tkanine (h) površinska masa

U sljedećoj fazi je za razvoj modela FL i sve matematičke proračune korišten Fuzzy Toolbox programskog paketa MATLAB. Kod vrednovanja tehnikom FL prvo su određeni odnosi između ulaznih i izlaznih parametara, uzimajući u obzir stručna mišljenja. Proces fazifikacije (omekšavanja) ulaznih i izlaznih varijabli provedeni su prema literaturi i mišljenjima stručnjaka. Stvorene su funkcije

članstva i pravila „AKO-ONDA“. U stroju za neizrazito zaključivanje „MAX-MIN“ korišten je mehanizam za zaključivanje. Mamdani metoda korištena je kao metoda zaključivanja koja se uobičajeno koristi i osnova je drugih modela FL. Nakon rješenja primijenjenog sustava FL, koji je dobio Mamdani metodom, rješenje je upravljano obrnuto što se naziva defazifikacija (izoštavanje). Za defazi-

fikaciju korištena je centroidna metoda (središte područja).

3. Rezultati i rasprava

Za predviđanje ponašanja, odnosno svojstva zrakopropusnosti primjenom metoda ANN i FL izmjereni su parametri pređe i tkanine koji utječu na zrakopropusnost prema literaturi: duljinska masa pređe, uvojitost, gustoća tkanine u smjeru osnove i pot-

ke, površinska masa i debljina. U tab.1 prikazani su eksperimentalno dobiveni rezultati, odnosno izmjerenе vrijednosti parametara zrakopropusnosti tkanine.

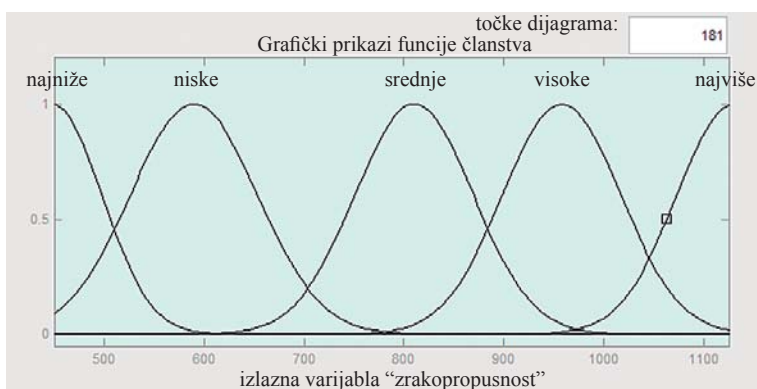
3.1. Model umjetne neuronske mreže (ANN)

Za potrebe ispitivanja konstruiran je troslojni unaprijedni algoritam s povratim rasprostiranjem greške koji ima 10 skrivenih neurona i model ANN s jednim izlaznim neuronom. Osim toga, 8 ulaznih neurona korišteno je za 8 ulaznih varijabli: duljinska masa osnove i potke, uvojitost osnove i potke, gustoća tkanine u smjeru osnove i potke, površinska masa i debljina tkanine. Na sl.1 prikazan je model ANN kojeg je proizveo MATLAB Neural Network Toolbox. U tab.2 prikazana je usporedba eksperimentalnih rezultata i izlaznih podataka ANN te izlaznih defazificiranih izlaznih vrijednosti, uz prikaz njihovih razlika u postocima. Prema dobivenim rezultatima predviđanja ANN modelom su bliža eksperimentalnim rezultatima.

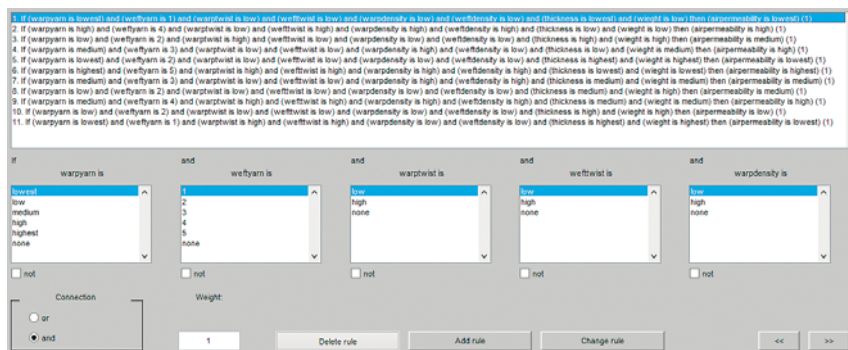
3.2. Model neizrazite logike (FL)

Metoda neizrazite logike (FL) bio je drugi model predviđanja zrakopropusnosti tkanine. Kod konstrukcije modela FL korišteni su: duljinska masa pređe, uvojitost pređe, gustoća tkanine u smjeru osnove i potke, površinska masa i debljina kao ulazne varijable, a zrakopropusnost je korištena kao izlazna varijabla isto kao u modelu ANN. Brojevi ulaznih i izlaznih funkcija članstva određeni su pomoću eksperimentalnih rezultata i stručnog mišljenja.

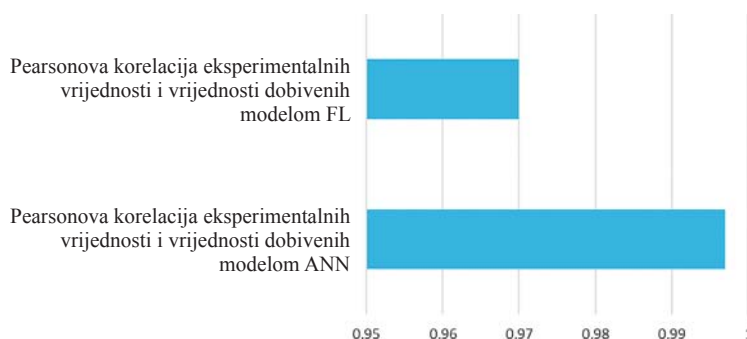
Na sl.2 prikazan je konstruirani model FL koji se sastoji od 8 neizrazitih ulaznih podataka, Mamdani operatora za zaključivanje i izlaznih podataka. Da bi se detaljnije odredile definirajuće vrijednosti članstva, korišteno je 5 funkcija članstva: najmanja, mala, srednja, velika i najveća za ulazne parametre tj. debljinu, površinsku masu te duljinsku masu osnove i potke. Za ostale ulazne parametre



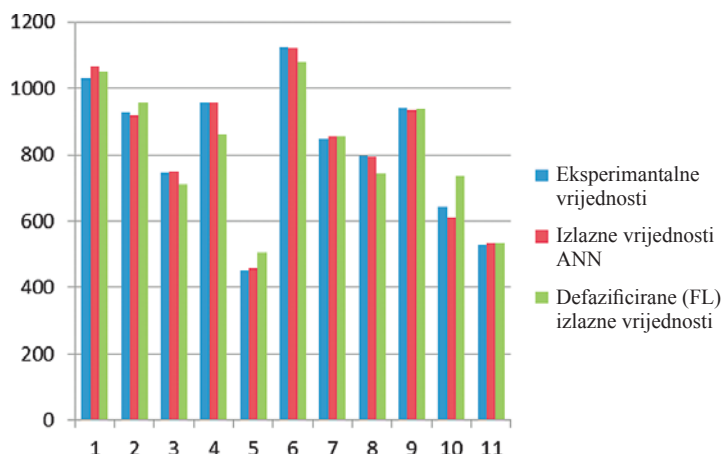
Sl.4 Funkcije članstva izlazne varijable



Sl.5 Neizrazita pravila "AKO-ONDA"



Sl.6 Pearsonove korelacije zrakopropusnosti eksperimentalnih vrijednosti i vrijednosti predviđenih modelima ANN i FL



Sl.7 Grafički prikaz vrijednosti zrakopropusnosti tkanina dobivenih eksperimentalno, predviđanjem ANN i FL metodom

korištene su dvije funkcije članstva: mala i velika. Funkcije članstva ulaznih varijabli prikazane su na sl.3 (a-h). Kod ispitivanja korišteno je 5 funkcija članstva za izlaznu varijablu. Na sl.4 prikazane su funkcije članstva izlazne varijable.

Za model FL pravila „AKO-ONDA“ su stvorena prema eksperimentalnim vrijednostima i mišljenjima stručnjaka. Za svaki uzorak stvoreno je pravilo i 11 pravila je korišteno za model FL. Pravila „AKO-ONDA“ koja su upotrijebljena u ispitivanju prikazana su na sl.5.

Vrijednosti predviđene zrakopropusnosti dobivene modelom FL uspoređene su s rezultatima zrakopropusnosti koji su dobiveni eksperimentalnim ispitivanjem. Usporedbe između eksperimentalnih rezultata i defazificiranih izlaznih podataka i njihova razlika u postocima navedene su u tab.2 za model FL. Kod ispitivanja korišten je centroidni proračun za postupak defazifikacije kojim se izračunava središte područja ispod krivulje [24]. Kako se može vidjeti iz tablice, premda su predviđana FL također bliža eksperimentalnim vrijednostima, rezultati ANN su bili mnogo bolji nego defazificirani izlazni podaci FL.

3.3. Usporedba metoda ANN i FL

U istraživanju su eksperimentalne vrijednosti zrakonepropusnosti procijenjene metodama ANN i FL. Vrijednosti dobivene eksperimentalnim ispitivanjima uspoređene su s izlaznim vrijednostima dobivenim postavljenim ANN i FL modelima pomoću Pearsonove korelacije. Ustanovljeno je da Pearsonve korelacije zrakonepropusnosti između eksperimentalnih vrijednosti i vrijednosti dobivenih predviđanjem pomoću modela ANN i FL iznose 0,997 (p-vrijednost (0,000) odn. 0,970 (p-vrijednosti 0,000). Na sl.6 prikazane su Pearsonove korelacije između eksperimentalnih vrijednosti i vrijednosti predviđenih modelima ANN i FL.

Budući da su postignute dobre korelacije vrijednosti predviđenih ANN i

FL s eksperimentalnim rezultatima, utvrđene su njihova korisnost i dobra mogućnost predviđanja. Međutim, prema Pearsnovoj korelaciji može se reći da su za opis stvarnih vrijednosti zrakopropusnosti tkanine izlazne vrijednosti primjenom ANN modela pouzdanije nego izlazne vrijednosti dobivene FL modelom. Na sl.7 usporedno su prikazane vrijednosti dobivene eksperimentalnim mjerenjima te ANN i FL metodama predviđanja zrakopropusnosti. Uočava se bolja podudarnost izlaznih vrijednosti ANN metodom s eksperimentalno dobivenim vrijednostima.

4. Zaključak

U ovom istraživanju su ispitane mogućnosti predviđanja svojstava zrakopropusnosti lanenih tkanina ANN i FL metodama. Ispitivanja su provedena tako da su najprije dobiveni eksperimentalni rezultati mjerenja vrijednosti zrakopropusnosti tkanina s obzirom na parametre pređa i tkanina. Ustanovljeno je da površinska masa najviše utječe na eksperimentalne vrijednosti zrakopropusnosti tkanina. Duljinska masa pređa u tkanini i debljina tkanine su po važnosti drugi parametri. Prema literaturnim podacima je poznato da debljina i površinska masa tkanina imaju obrnuto proporcionalnu vezu sa svojstvom zrakopropusnosti, povećanje tih parametara mogu uzrokovati smanjenje zrakopropusnosti. S druge strane, povećanje duljinske mase pređa uzrokuje povećanje zrakopropusnosti.

Duljinska masa pređa, uvijitost, gustoće tkanine u smjeru osnove i potke, površinska masa i debljina tkanina su parametri korišteni kao ulazne varijable, a zrakopropusnost je korištena kao izlazna varijabla u modelima ANN i FL.

Izlazne vrijednosti za predviđanje zrakopropusnosti dobivene modelima ANN i FL uspoređene s vrijednostima dobivenim eksperimentalnim ispitivanjima. Utvrđeno je da se ANN i FL modelima dobivaju vrijednosti slične eksperimentalno dobivenim

vrijednostima. Međutim, predviđanje primjenom ANN modela je pouzdanije i učinkovitije za predviđanje svojstva zrakopropusnosti lanenih tkanina. Optimiranjem ovih modela bilo bi moguće predvidjeti ponašanje zrakopropusnosti tkanina prije njihove proizvodnje samo ako se točno odrede parametri tkanine.

Modeli ANN i FL često se upotrebljavaju u tekstilnoj industriji. U ovom radu su primijenjeni za lanene tkanine. U tom kontekstu smatra se da je ovo istraživanje utvrdilo vrijedne podatke koji kombinira tehnike mekog računalstva, kao što su umjetna neuronska mreža i neizrazita logika za vrednovanje zrakopropusnosti lanenih tkanina. Određena je najbolja metoda predviđanja oj svojstva u odnosu na eksperimentalno dobivene rezultate.

(Preveo M. Horvatić)

Literatura:

- [1] Oğulata R.T.: Air permeability of woven fabrics, *Journal of Textile and Apparel, Technology and Management* 5 (2006.) 2, 1-10
- [2] Oğulata R.T., S. Mavruz Mezarciöz: Total porosity theoretical analysis, and prediction of the air permeability of woven fabrics, *The Journal of the Textile Institute* 103 (2012.) 6, 654-661
- [3] Fatahi I., A.A. Yazdi: Predicting air permeability from the parameters of weave structure, *Fibres & Textiles in Eastern Europe* 20 (2012.) 3, 78-81
- [4] Havlova M.: Air permeability and constructional parameters of woven fabrics, *Fibres & Textiles in Eastern Europe*, V.21, (2013.) 2, 84-89
- [5] Zupin Z. et al.: Prediction of one-layer woven fabrics air permeability using porosity parameters, *Textile Research Journal* 82 (2011.) 2, 117-128
- [6] Petruyte S., R. Baltakyte: An investigation into air permeability of terry fabrics regarding the processes of finishing, *Tekstil* 57 (2008.) 1-2, 15-20
- [7] Özdil N.: Physical quality control methods in fabrics, *E.U. Textile*

- and Apparel Textile & Apparel Research and Application Center, Izmir, 2003., ISBN 975-483-579-9
- [8] Majumdar A. et al.: Soft computing applications in fabrics and clothing: A comprehensive review, *Research Journal of Textile and Apparel* 14 (2010.) 1, 1-17
- [9] Vassiliadis S. et al.: Artificial neural networks and their applications in the engineering of fabrics, *Woven Fabric Engineering*, InTech, Available from: <http://www.intechopen.com/books/woven-fabric-engineering/artificial-neural-networks-and-their-applications-in-the-engineering-of-fabrics>, 2010., 26 page
- [10] Majumdar A.: Soft computing in fibrous materials engineering, *Textile Progress* 43 (2011.) 1, 1-95
- [11] Matusiak M.: Application of artificial neural networks to predict the air permeability of woven fabrics, *Fibres & Textiles in Eastern Europe* 23 (2015.) 1, 41-48
- [12] Çay A. et al.: Prediction of the air permeability of woven fabrics using neural networks, *International Journal of Clothing Science and Technology* 19, (2007.) 1, 18-35
- [13] Militky J. et al.: Influence of fabric construction on the their porosity and air permeability, Available from: http://centrum.tul.cz/centrum/centrum/1Projektovani/1.2_publikace/%5B1.2.30%5D.pdf, access date, 2017., 18 page
- [14] Abou-Nassif G.A.: Predicting the tensile and air permeability properties of woven fabrics using artificial neural network and linear regression models, *Journal of Textile Science & Engineering* 5 (2015.) 5, 1-6
- [15] Tokarska M.: Assessing the quality of neural models using a model of flow characteristics of fabrics as an example, *Autex Research Journal* 6 (2006.) 3, 162-168
- [16] Dayık M., F. Yılmaz: Cotton fabric pilling detection with fuzzy logic method, *Electronic Journal of Textile Technologies* 6 (2012.) 2, 19-27
- [17] Sette S. et al.: Building a rule set for the fiber-to-yarn production process by means of soft computing techniques, *Textile Research Journal* 70 (2000.) 5, 375-386
- [18] Park S.W. et al.: Applying fuzzy logic and neural networks to total hand evaluation of knitted fabrics, *Textile Research Journal* 70 (2000.) 8, 675-681
- [19] Kılıç, M.: Determination of fabric drape using image analysis and fuzzy-logic methods, *Industria Textila* 66 (2015.) 5, 269-277
- [20] Hussain T. et al.: Comparison of artificial neural network and adaptive neuro-fuzzy inference system for predicting the wrinkle recovery of woven fabrics, *The Journal of the Textile Institute* 106 (2015.) 9, 934-938
- [21] Özçelik G.: A research on the objective evaluation and prediction of fabric pilling property, PhD Thesis, Textile Engineering Department of Ege University, Turkey, 2009., 315 page
- [22] Yuan H.C. et al.: Method for estimating the number of hidden neurons in feed-forward neural networks based on information entropy, *Computers and Electronics in Agriculture* 40 (2003.) 1-3, 57-64
- [23] Huang G-B., H.A. Babri: Upper bounds on the number of hidden neurons in feedforward networks with arbitrary bounded nonlinear activation functions, *IEEE Transactions on Neural Networks* 9 (1998.) 1, 224-229
- [24] MATLAB. Fuzzy Logic Toolbox User's Guide, Mathworks R2015b, 2015.

SUMMARY**Application of soft computing techniques
for the prediction of the air permeability property of fabrics***S. Altaş*

The air permeability of a fabric is the measure of the air flow rate through the fabric under a given pressure. It has a great significance on the fabric comfort related properties of clothing. The target of the study is the application of fuzzy logic and artificial neural network simulation for the estimation of the air permeability of the linen woven fabrics. For this aim, eleven different linen woven fabrics were used and their basic physical properties such as; yarn linear density, twist coefficient, fabric unit weight, fabric thickness and air permeability properties were evaluated. The air permeability property of linen fabrics was predicted by using Fuzzy Logic (FL) and Artificial Neural Network (ANN) models using the parameters which are effective on air permeability according to the literature. The predictions of ANN and FL methods compared with experimental results. According to the results, it was seen that ANN and FL models give outputs closer to experimental results, but the estimation success of ANN method was found better than the FL model.

Key words: soft computing techniques, Fuzzy Logic (FL), Artificial Neural Network (ANN), air permeability, linen, woven fabric

Ege University Emel Akın Vocational Training School, Textile Program

Ege University Campus, Bornova

İzmir, Turkey

e-mail: sevda.altas@ege.edu.tr

Received December 20, 2016

**Anwendung von Soft-Computing-Techniken für die Vorhersage
der Luft-Durchlässigkeit-Eigenschaft von Geweben**

Die Luftdurchlässigkeit eines Gewebes ist das Maß für den Luftdurchsatz durch das Gewebe unter einem gegebenen Druck. Es hat eine große Bedeutung für die Komforteigenschaften der Bekleidungsstoffe. Ziel der Studie war die Anwendung der Simulation der Fuzzylogik und künstlicher neuronaler Netzwerke für die Einschätzung der Luftdurchlässigkeit der Leinengewebe. Zu diesem Zweck wurden elf verschiedene Leinengewebe verwendet und ihre grundlegenden physikalischen Eigenschaften wie: lineare Garndichte, Drehungskoeffizient, Gewichtseinheit des Gewebes, Gewebedicke und Luftdurchlässigkeitseigenschaften ausgewertet. Die Luftdurchlässigkeitseigenschaft von Leinengeweben wurde mittels der Modelle der Fuzzy-Logik (FL) und des künstlichen neuronalen Netzwerks (ANN) unter Verwendung der Parameter, die auf der Luftdurchlässigkeit gemäß der Literatur wirksam sind, vorhergesagt. Die Vorhersagen von ANN- und FL-Methoden wurden mit experimentellen Ergebnissen verglichen. Gemäß den Ergebnissen wurde festgestellt, dass ANN- und FL-Modelle Ergebnisse, die näher zu experimentellen Ergebnissen sind, liefern, aber es wurde festgestellt, dass der Bewertungserfolg der ANN-Methode besser als bei dem FL-Modell ist.