



UNIVERZITET U NOVOM SADU
TEHNOLOŠKI FAKULTET
HEMIJSKO INŽENJERSTVO

***MODELOVANJE MIKROFILTRACIJE
KULTIVACIONIH TEČNOSTI PRIMENOM
KONCEPTA VEŠTAČKIH NEURONSKIH
MREŽA***

DOKTORSKA DISERTACIJA

Mentor:

Prof. dr Aleksandar Jokić

Kandidat:

Nevenka Nikolić, dipl. ing.

Novi Sad, 2020. godine

**UNIVERZITET U NOVOM SADU
TEHNOLOŠKI FAKULTET**

KLJUČNA DOKUMENTACIJSKA INFORMACIJA

Redni broj: RBR	
Identifikacioni broj: IBR	
Tip dokumentacije: TD	Monografska dokumentacija
Tip zapisa: TZ	Tekstualni štampani materijal
Vrsta rada (dipl., mag., dokt.): VR	Doktorska disertacija
Ime i prezime autora: AU	Nevenka Nikolić
Mentor (titula, ime, prezime, zvanje): MN	Dr. Aleksandar Jokić, vanredni profesor Tehnološkog fakulteta u Novom Sadu
Naslov rada: NR	Modelovanje mikrofiltracije kultivacionih tečnosti primenom koncepta veštačkih neuronskih mreža
Jezik publikacije: JP	Srpski (latinica)
Jezik izvoda: JI	Srpski / Engleski.
Zemlja publikovanja: ZP	Republika Srbija
Uže geografsko područje: UGP	AP Vojvodina
Godina: GO	2020
Izdavač: IZ	Autorski reprint
Mesto i adresa: MA	Tehnološki fakultet, 21000 Novi Sad, Bul. cara Lazara 1

Fizički opis rada: FO	(8 poglavlja / 183 stranice / 40 slika / 18 tabela / 127 referenci / 6 priloga)
Naučna oblast: NO	Tehnološko inženjerstvo
Naučna disciplina: ND	Hemijsko inženjerstvo
Predmetna odrednica, ključne reči: PO	Mikrofiltracija, kultivacione tečnosti, neuronske mreže
UDK	
Čuva se: ČU	Biblioteka Tehnološkog fakulteta Univerziteta u Novom Sadu
Važna napomena: VN	nema
Izvod: IZ	<p>Fokus ove doktorske disertacije je razvijanje modela zasnovanog na konceptu veštačkih neuronskih mreža za predviđanje i projektovanje mikrofiltracije kultivacionih tečnosti preko ispitivanja mogućnosti primene ovog koncepta za modelovanje fluksa permeata pri različitim uslovima mikrofiltracije, u sistemima sa i bez primene hidrodinamičkih metoda poboljšanja fluksa permeata i njihove kombinacije, kao i razvoj modela kojim će se objediniti eksperimentalni rezultati u cilju dobijanja jedne jedinstvene neuronske mreže za simulaciju svih metoda poboljšanja fluksa. Dodatan cilj predstavlja razvoj modela za procenu poboljšanja fluksa u stacionarnim uslovima usled primene metoda poboljšanja fluksa permeata čija će se adekvatnost proveriti sa energetskeg stanovišta.</p> <p>Eksperimentalna ispitivanja su obuhvatila razvoj i validaciju deset različitih modela neuronskih mreža kod kojih su nezavisne ulazne promenljive i njihovi rasponi (transmembranski pritisak, protok suspenzije i protok vazduha) utvrđeni Box-Behnken-ovim eksperimentalnim planom uz dodatne parametre vreme trajanja mikrofiltracije i temperature koji su varirani u zavisnosti od uslova izvođenja postupka mikrofiltracije. Nasuprot tome, za razvoj dinamičkog modela u svojstvu zavisno promenljive veličine razmatran je pad fluksa permeata sa vremenom, dok je za razvoj modela procene efikasnosti primenjenih metoda poboljšanja fluksa permeata razmatran fluks i specifična potrošnja energije u stacionarnim uslovima.</p> <p>Normalizacijom eksperimentalnih podataka izbegla se velika razlika u specifičnim težinskim koeficijentima pojedinih ulaznih promenljivih i</p>

predupredila opasnost da te promenljive pokažu veći uticaj nego što ga imaju u realnosti, a balansiranje efekata nekontrolisanih faktora na izlaznu promenljivu izvedeno je randomizacijom na grupu za obučavanje (70% podataka), grupu za validaciju (15% podataka) i grupu za testiranje (15% podataka). Nestacionarnosti koje utiču na efikasnost algoritma obuke i arhitekture neuronskih mreža izbegnute su ispitivanjem modela sa pet algoritama obuke (Levenberg–Markuardt-ov algoritam obuke (*trainlm*), Bayes-ova regularizacija (*trainbr*), model rezilientnog povratnog prostiranja (*trainrp*), model skaliranog konjugovanog gradijenta (*trainscg*) i model jednostepenog sekantnog povratnog prostiranja greške unazad (*trainoss*)) i dve sigmoidalne aktivacione funkcije u skrivenom sloju (logistička i hiperbolična tangensna), dok je u izlaznom sloju korišćena linearna aktivaciona funkcija. Svi modeli su optimizovani primenom metode probe i greške sa osnovnim ciljem dobiti što jednostavniju mrežu, odnosno mrežu sa minimalnim brojem skrivenih neurona koja pokazuje najbolju sposobnost generalizacije. Kao indikatori nivoa generalizacije i parametara učinka obuke neuronske mreže ispitivani su koeficijent determinacije (R^2) i srednja kvadratna greška (MSE), a koeficijent korelacije (r) je odabran kao dodatni parametar adekvatnosti fitovanja vrednosti utvrđenog i neuronskom mrežom procenjenog fluksa permeata. Najbolju sposobnost generalizacije i predikcije pokazao je model neuronske mreže obučavan Levenberg-Markuardt-ovim algoritmom. Optimalan broj neurona u skrivenom sloju se kretao od 7 do 13 što ukazuje na znatnu kompleksnost mehanizama koji utiču na fluks permeata kako je i procenjeno postavljanjem hipoteze ove doktorske disertacije. Analiza apsolutne relativne greške pokazala je veoma dobro predviđanje pošto je u rasponu od 81% do 100% podataka imalo grešku manju od 10%, a koeficijent determinacije u rasponu od 0,98091 do 0,99976 ukazuje da mreža ne može da objasni manje od 2% varijacija u sistemu. Vrednosti koeficijenta korelacije se kreću u rasponu od 0,99041 do 0,99988 što sugerise na dobru linearnu korelaciju između eksperimentalnih podataka i podataka predviđenih neuronskom mrežom. Pored primene koncepta fitovanja podataka ispitana je i mogućnost procene uticaja pojedinih eksperimentalnih promenljivih na fluks permeata primenom jednačine Garsona, a komparativnom analizom dobijenih simulacionih

	rezultata na eksperimentalim podacima koji nisu bili predstavljeni neuronskoj mreži potvrđen je generalizacijski kapacitet modela neuronske mreže.
Datum prihvatanja teme od strane Senata: DP	27.06.2019.
Datum odbrane: DO	
Članovi komisije: (ime i prezime / titula / zvanje / naziv organizacije / status) KO	<p>predsednik: dr. Bojana Ikonić, vanredni profesor Tehnološki fakultet Novi Sad Univerzitet u Novom Sadu</p> <p>član: dr Olivera Stamenković, redovni profesor Tehnološki fakultet Leskovac Univerzitet u Nišu</p> <p>član: dr Jovana Grahovac, vanredni profesor Tehnološki fakultet Novi Sad Univerzitet u Novom Sadu</p> <p>član: dr Nataša Lukić, docent Tehnološki fakultet Novi Sad Univerzitet u Novom Sadu</p> <p>član/mentor: dr Aleksandar Jokić, vanredni profesor Tehnološki fakultet Novi Sad Univerzitet u Novom Sadu</p>

University of Novi Sad
Faculty of Tehnology
Key word documentation

Accession number: ANO	
Identification number: INO	
Document type: DT	Monograph documentation
Type of record: TR	Textual printed material
Contents code: CC	Ph.D. thesis
Author: AU	Nevenka Nikolić
Mentor: MN	Dr. Aleksadar Jokić, associate professor
Title: TI	Modeling of fermentation broth microfiltration by artificial neural networks
Language of text: LT	Serbian (Latin)
Language of abstract: LA	Serbian / English
Country of publication: CP	Republic of Serbia
Locality of publication: LP	AP Vojvodina
Publication year: PY	2020
Publisher: PU	Author reprint
Publication place: PP	Faculty of Tehnology, 21000 Novi Sad, Bul. cara Lazara 1

Physical description: PD	8 chapters, 183 pages, 40 figures, 18 tables, 127 references, 6 attachment
Scientific field SF	Chemical engineering
Scientific discipline SD	Chemical processing engineering
Subject, Key words SKW	Microfiltration, fermentation broth, neural networks
UC	
Holding data: HD	Library of Faculty of Technology Novi Sad, 21000 Novi Sad, Serbia, Bul. cara Lazara 1
Note: N	No notes
Abstract: AB	<p>Focus of this doctoral dissertation is to develop a model based on the artificial neural networks concept for predicting and designing cultivation broth microfiltration by examining the feasibility of this concept for modeling permeate flux under different microfiltration conditions, in systems with and without hydrodynamic improvement methods , as well the development of a model that will combine the experimental results in order to obtain a single neural network to simulate all methods of flux improvement. An additional goal is the development of a model in quasi steady state in terms of adequacy of flux enhancement methods application, which will be checked from the energy point of view.</p> <p>Experimental tests included the development and validation of ten different models of neural networks in which the independent input variables and their ranges (transmembrane pressure, suspension flow and air flow) were determined by Box-Behnken's experimental plan with added microfiltration parameters time and temperature, varied depending on the conditions of the microfiltration procedure. In contrast, for the development of a dynamic model as a dependent variable, the decrease in permeate flux with time was considered, while for the development of a model for evaluating the efficiency of applied permeate flux improvement methods, flux and specific energy consumption in quasi steady state conditions were considered.</p> <p>Normalization of experimental data avoided a large difference in specific weight coefficients</p>

of individual input variables and prevented the danger that these variables show a greater impact than they have in reality, and balancing the effects of uncontrolled factors on the output variable was performed by randomization on the training group (70% of data), a validation group (15% of data) and a testing group (15% of data). Non-stationarities affecting the efficiency of the training algorithm and neural network architecture were avoided by testing the model with five different training algorithms (Levenberg–Marquardt training algorithm (trainlm), Bayesian regularization (trainbr), resilient backpropagation algorithm (trainrp), scaled conjugate gradient method (trainscg) and a one-step secant method (trainoss)) and two sigmoid activation functions in the hidden layer (logistic and hyperbolic tangent), while a linear activation function was used in the output layer. All models are optimized by applying the trial and error method with the basic goal of having the simplest possible network, ie a network with a minimum number of hidden neurons that shows the best ability to generalize. Determination coefficient (R^2) and mean square error (MSE) were examined as indicators of generalization level and neural network training performance parameters, and correlation coefficient (r) was selected as an additional parameter of adequacy of fitting the value of determined and neural network estimated permeate flux.

The best ability to generalize and predict was shown by a model of a neural network trained by the Levenberg-Marquardt algorithm. The optimal number of neurons in the hidden layer ranged from 7 to 13, which indicates a significant complexity of the mechanisms that affect the permeate flux, as assessed by the hypothesis of this doctoral dissertation.

Absolute relative error analysis showed very good prediction as in the range of 81% to 100% of the data had an error of less than 10%, and the coefficient of determination in the range of 0.98091 to 0.99976 indicates that the network cannot explain less than 2 % variation in the system. The values of the correlation coefficient range from 0.99041 to 0.99988 suggests a good linear correlation between the experimental data and the data predicted by the neural network. In

	<p>addition to the application of the concept of data fitting, the relative importance of input variables was also investigated by applying the Garson equation. Comparative analysis of the obtained simulation results on experimental data that were not presented to the neural network confirmed the generalization capacity of the neural network model.</p>
<p>Accepted on Senate on: AS</p>	<p>27.06.2019.</p>
<p>Defended: DE</p>	
<p>Thesis Defend Board: DB</p>	<p>president: Bojana Ikonić, PhD, associate professor, Faculty of Technology Novi Sad, University of Novi Sad</p> <p>member: Olivera Stamenković, PhD, full professor, Faculty of Technology Leskovac, University of Niš</p> <p>member Jovana Grahovac, PhD, associate professor, Faculty of Technology Novi Sad, University of Nov Sad</p> <p>member: Nataša Lukić, PhD, assistant professor, Faculty of Technology Novi Sad, University of Novi Sad</p> <p>mentor: Aleksandar Jokić, PhD, associate professor, Faculty of Technology Novi Sad, University of Novi Sad</p>

Zahvalnica

Ova doktorska disertacija je rezultat dugogodišnjeg rada na polju primene veštačkih neuronskih mreža za modelovanje mikrofiltracije kultivacionih tečnosti. Stoga koristim priliku da se zahvalim posebnim osobama koje su dale svoj doprinos tokom njene izrade.

Pre svega, želea bih da izrazim duboku zahvalnost svom mentoru, prof. dr Aleksandru Jokiću, na inspiraciji za sprovedeno istraživanje, ukazanoj podršci i smernicama u procesu izrade disertacije, vrednim povratnim informacijama i podsticaju na svakom koraku moga stručnog rada. Za izuzetno korisne sugestije i komentare posebno bih želela da se zahvalim prof. dr. Nataši Lukić, kao i ostalim članovima komisije prof. dr. Bojani Ikonić, prof. dr. Oliveri Stamenković i prof. dr. Jovani Grahovac.

Svakako, ogromnu zahvalnost dugujem svojim roditeljima, na ljubavi i podršci koju su mi pružili, jer su oni zaslužni za to kakav sam čovek postala, znam da bi bili veoma ponosni na mene, što ovu disertaciju čini još vrednijom.

I na kraju, od srca hvala mojim najdražima, Francu koji me je bodrio u najtežim trenucima i pomogao mi da istrajem na ovom, nimalo jednostavnom putu i bratu Aleksandru za svu pomoć i veru koju mi je pružio.

Nevenka Nikolić

SADRŽAJ

SPISAK SLIKA	iii
SPISAK TABELA	vi
UVOD	1
1. CILJ ISTRAŽIVANJA	3
PREGLED LITERATURE	4
2. Membranski separacioni procesi	4
2.1. Mikrofiltracija	7
2.2. Postupci za poboljšanje fluksa permeata	8
3. Modelovanje mikrofiltracije	12
3.1. Teorijski i semiteorijski modeli	12
3.2. Empirijski modeli	23
3.3. Problemi u modelovanju membranskih separacionih procesa	26
4. Koncept veštačkih neuronskih mreža	28
4.1 Veštačke neuronske mreže u modelovanju mikrofiltracije	33
EKSPERIMENTALNI DEO I REZULTATI	41
5. Materijal i metod	41
5.1 Eksperimentalni plan i metod	41
5.2. Dizajn neuronske mreže i obrada podataka	46
6. Rezultati i diskusija	54
6.1. Modelovanje mikrofiltracije tokom ugušćivanja	54
6.1.1. Validacija i verifikacija modela neuronske mreže u uslovima ugušćivanja	66
6.1.2. Relativni značaj ulaznih promenljivih u uslovima ugušćivanja	69
6.2. Modelovanje mikrofiltracije u uslovima recirkulacije napojne smeše	72
6.2.1. Validacija i verifikacija modela neuronske mreže u uslovima recirkulacije napojne smeše	82
6.2.2. Relativni značaj ulaznih promenljivih u uslovima recirkulacije napojne smeše	85
6.3. Modelovanje mikrofiltracije u uslovima dvofaznog toka	88
6.3.1. Validacija i verifikacija modela neuronske mreže u uslovima dvofaznog toka	92
6.3.2. Relativni značaj ulaznih promenljivih u uslovima dvofaznog toka	95
6.4. Modelovanje mikrofiltracije u uslovima kombinovane primene promotora turbulencije i dvofaznog toka	99
6.4.1. Validacija i verifikacija modela neuronske mreže uz primenu promotora turbulencije i dvofaznog toka	103
6.4.2. Relativni značaj ulaznih promenljivih mikrofiltracije u uslovima kombinovane primene promotora turbulencije i dvofaznog toka	106
6.5. Modelovanje objedinjenih podataka mikrofiltracije kultivacione tečnosti <i>Bacillus velezensis</i>	109
6.5.1. Validacija i verifikacija modela neuronske mreže objedinjenih podataka mikrofiltracije kultivacione tečnosti <i>Bacillus velezensis</i>	113
6.5.2. Relativni značaj ulaznih promenljivih objedinjenih podataka mikrofiltracije kultivacione tečnosti <i>Bacillus velezensis</i>	117
6.6. Modelovanje u stacionarnim uslovima	121
6.6.1. Modelovanje stacionarnog fluksa	122
6.6.1.1. Validacija i verifikacija modela neuronske mreže u uslovima stacionarnog fluksa	126
6.6.1.2. Relativni značaj ulaznih promenljivih mikrofiltracije u stacionarnim uslovima ..	129

6.6.2. Modelovanje specifične potrošnje energije	132
6.6.2.1. Validacija i verifikacija modela neuronske mreže specifične potrošnje energije u stacionarnim uslovima	136
6.6.2.2. Relativni značaj ulaznih promenljivih mikrofiltracije na specifičnu potrošnju energije u stacionarnim uslovima	139
7. Zaključak.....	142
8. Literatura.....	146
PRILOG 1.....	162
PRILOG 2.....	166
PRILOG 3.....	170
PRILOG 4.....	172
PRILOG 5.....	174
PRILOG 6.....	176

SPISAK SLIKA

Slika 2.1.1. Tok fluida u procesu membranske separacije.....	4
Slika 2.2.1. Šematski prikaz transferzalnog i unakrsnog režima proticanja napojne smeše..	7
Slika 4.1.1. Struktura biološkog neurona.....	28
Slika 4.1.2. Struktura veštačkog neurona.....	29
Slika 6.1.1. Varijacija vrednosti srednje kvadratne greške sa brojem neurona skrivenog sloja mikrofiltracije kultivacione smeše <i>Streptomyces hygroscopicus</i> u uslovima ugušćivanja u NSM režimu.....	58
Slika 6.1.2. Varijacija vrednosti koeficijenta determinacije sa brojem neurona skrivenog sloja mikrofiltracije kultivacione smeše <i>Streptomyces hygroscopicus</i> u uslovima ugušćivanja u NSM režimu.....	59
Slika 6.1.3. Varijacija srednje kvadratne greške sa brojem neurona u skrivenom sloju mikrofiltracije kultivacione smeše <i>Streptomyces hygroscopicus</i> u uslovima ugušćivanja u SM režimu.....	60
Slika 6.1.4. Varijacija koeficijenta determinacije sa brojem neurona u skrivenom sloju mikrofiltracije kultivacione smeše <i>Streptomyces hygroscopicus</i> u uslovima ugušćivanja u SM režimu.....	61
Slika 6.1.5. Varijacija srednje kvadratne greške sa brojem neurona u skrivenom sloju mikrofiltracije kultivacione smeše <i>Streptomyces hygroscopicus</i> u uslovima ugušćivanja u oba režima.....	64
Slika 6.1.6. Varijacija koeficijenta determinacije sa brojem neurona u skrivenom sloju mikrofiltracije kultivacione smeše <i>Streptomyces hygroscopicus</i> u uslovima ugušćivanja u oba režima.....	64
Slika 6.1.7. Dijagram linearne regresije za mikrofiltraciju kultivacione smeše <i>Streptomyces hygroscopicus</i> u uslovima ugušćivanja: a) režim bez statičkog promotora turbulencije, b) režim sa statičkim promotorom turbulencije.....	67
Slika 6.1.8. Verifikacija modela neuronske mreže za denormalizovane vrednosti fuksa permeata mikrofiltracije kultivacione smeše <i>Streptomyces hygroscopicus</i> u uslovima ugušćivanja: a) u režimu sa statičkim promotorom turbulencije, b) u režimu bez statičkog promotora turbulencije.....	68
Slika 6.2.1. Varijacija vrednosti srednje kvadratne greške sa brojem neurona skrivenog sloja mikrofiltracije kultivacione tečnosti <i>Bacillus velezensis</i> u uslovima recirkulacije napojne smeše u NSM režimu.....	75
Slika 6.2.2. Varijacija koeficijenta determinacije sa brojem neurona skrivenog sloja mikrofiltracije kultivacione tečnosti <i>Bacillus velezensis</i> u uslovima recirkulacije napojne smeše u NSM režimu.....	75
Slika 6.2.3. Varijacija vrednosti srednje kvadratne greške sa brojem neurona skrivenog sloja mikrofiltracije kultivacione tečnosti <i>Bacillus velezensis</i> u uslovima recirkulacije napojne smeše u SM režimu.....	78
Slika 6.2.4. Varijacija vrednosti koeficijenta determinacije sa brojem neurona skrivenog sloja mikrofiltracije kultivacione tečnosti <i>Bacillus velezensis</i> u uslovima recirkulacije napojne smeše u SM režimu.....	78
Slika 6.2.5. Varijacija vrednosti srednje kvadratne greške sa brojem neurona u skrivenom sloju mikrofiltracije kultivacione tečnosti <i>Bacillus velezensis</i> u uslovima recirkulacije napojne smeše u oba režima.....	80
Slika 6.2.6. Varijacija vrednosti koeficijenta determinacije sa brojem neurona u skrivenom sloju mikrofiltracije kultivacione tečnosti <i>Bacillus velezensis</i> u uslovima recirkulacije napojne smeše u oba režima.....	81

Slika 6.2.7. Dijagram linearne regresije mikrofiltracije kultivacione tečnosti <i>Bacillus velezensis</i> u uslovima recirkulacije napojne smeše za: a) režim bez statičkog promotora turbulencije, b) režim sa statičkim promotorom turbulencije	83
Slika 6.2.8. Verifikacija modela neuronske mreže za denormalizovane vrednosti fuksa permeata mikrofiltracije kultivacione tečnosti <i>Bacillus velezensis</i> u uslovima recirkulacije napojne smeše : a) u režimu sa statičkim promotorom turbulencije, b) u režimu bez statičkog promotora turbulencije	85
Slika 6.3.1. Varijacija vrednosti srednje kvadratne greške sa brojem neurona skrivenog sloja mikrofiltracije kultivacione smeše <i>Bacillus velezensis</i> u uslovima dvofaznog toka...	90
Slika 6.3.2. Varijacija vrednosti koeficijenta determinacije sa brojem neurona skrivenog sloja mikrofiltracije kultivacione smeše <i>Bacillus velezensis</i> u uslovima dvofaznog toka...	91
Slika 6.3.3. Dijagram linearne regresije mikrofiltracije kultivacione smeše <i>Bacillus velezensis</i> u uslovima dvofaznog toka	93
Slika 6.3.4. Verifikacija modela neuronske mreže za denormalizovane vrednosti fluksa permeata u uslovima dvofaznog toka	94
Slika 6.4. 1. Varijacija vrednosti srednje kvadratne greške sa brojem neurona skrivenog sloja mikrofiltracije kultivacione smeše <i>Bacillus velezensis</i> u uslovima kombinovanog postupka	101
Slika 6.4. 2. Varijacija vrednosti koeficijenta determinacije sa brojem neurona skrivenog sloja mikrofiltracije kultivacione smeše <i>Bacillus velezensis</i> u uslovima kombinovanog postupka	102
Slika 6.4.3. Dijagram linearne regresije mikrofiltracije kultivacione smeše <i>Bacillus velezensis</i> kombinovanom primenom dvofaznog toka i promotora turbulencije	104
Slika 6.4.4. Verifikacija modela neuronske mreže za denormalizovane vrednosti fluksa permeata u uslovima kombinovane primene dvofaznog toka i promotora turbulencije....	105
Slika 6.5.1. Varijacija vrednosti srednje kvadratne greške sa brojem neurona skrivenog sloja mikrofiltracije kultivacione smeše <i>Bacillus velezensis</i> u uslovima primene svih metoda poboljšanja fluksa permeata	111
Slika 6.5.2. Varijacija vrednosti koeficijenta determinacije sa brojem neurona skrivenog sloja mikrofiltracije kultivacione smeše <i>Bacillus velezensis</i> u uslovima primene svih metoda poboljšanja fluksa permeata	112
Slika 6.5.3. Dijagram linearne regresije mikrofiltracije kultivacione tečnosti <i>Bacillus velezensis</i> u uslovima primene svih metoda poboljšanja fluksa permeata	113
Slika 6.5.4. Verifikacija modela neuronske mreže za denormalizovane vrednosti fluksa permeata u uslovima primene svih ispitivanih metoda poboljšanja fluksa permeata	115
Slika 6.6.1. Varijacija vrednosti srednje kvadratne greške sa brojem neurona skrivenog sloja mikrofiltracije kultivacione smeše <i>Bacillus velezensis</i> u stacionarnim uslovima.....	124
Slika 6.6.2. Varijacija vrednosti koeficijenta determinacije sa brojem neurona skrivenog sloja mikrofiltracije kultivacione smeše <i>Bacillus velezensis</i> u stacionarnim uslovima.....	125
Slika 6.6.3. Dijagram linearne regresije mikrofiltracije kultivacione tečnosti <i>Bacillus velezensis</i> u stacionarnim uslovima	127
Slika 6.6.4. Verifikacija modela neuronske mreže za denormalizovane vrednosti stacionarnog fluksa	128
Slika 6.6.5. Varijacija vrednosti srednje kvadratne greške sa brojem neurona skrivenog sloja mikrofiltracije kultivacione smeše <i>Bacillus velezensis</i> u stacionarnim uslovima za specifičnu potrošnju energije	134
Slika 6.6.6. Varijacija vrednosti koeficijenta determinacije sa brojem neurona skrivenog sloja mikrofiltracije kultivacione smeše <i>Bacillus velezensis</i> u stacionarnim uslovima za specifičnu potrošnju energije	135

Slika 6.6.7. Dijagram linearne regresije specifične potrošnje energije mikrofiltracije kultivacione tečnosti <i>Bacillus velezensis</i> u stacionarnim uslovima.....	137
Slika 6.6.8. Verifikacija modela neuronske mreže za denormalizovane vrednosti specifične potrošnje energije.....	138

SPISAK TABELA

Tabela 3.1.1. Hermia (1982) i Field (1995) modeli blokiranja pora tokom mikrofiltracije..	14
Tabela 3.2.1. Pregled pojedinih empirijski korelisanih jednačina fluksa permeata.....	23
Tabela 5.2.1. Aktivacione funkcije u neuronskoj mreži	48
Tabela 5.2.2. Distribucija podataka u modelu neuronske mreže	50
Tabela 6.1.1. Distribucija apsolutne relativne greške u uslovima ugušćivanja	68
Tabela 6.1.2. Relativni značaj ulaznih promenljivih u uslovima ugušćivanja.....	70
Tabela 6.2.1. Distribucija apsolutne relativne greške u uslovima recirkulacije napojne smeše.....	84
Tabela 6.2.2. Relativni značaj ulaznih promenljivih mikrofiltracije u uslovima recirkulacije napojne smeše	86
Tabela 6.3.1. Distribucija apsolutne relativne greške u uslovima dvofaznog toka.....	92
Tabela 6.3.2. Relativni značaj ulaznih promenljivih mikrofiltracije u uslovima dvofaznog toka.....	96
Tabela 6.4.1. Distribucija apsolutne relativne greške u uslovima kombinovanog postupka	104
Tabela 6.4.2. Relativni značaj ulaznih promenljivih mikrofiltracije u uslovima kombinovane primene promotora turbulencije i dvofaznog toka	106
Tabela 6.5.1. Distribucija apsolutne relativne greške objedinjenih podataka.....	114
Tabela 6.5.2. Relativni značaj ulaznih promenljivih mikrofiltracije objedinjenih podataka	118
Tabela 6.6.1. Distribucija apsolutne relativne greške predviđanja stacionarnog fluksa	127
Tabela 6.6.2. Relativni značaj ulaznih promenljivih na predviđanje stacionarnog fluksa	130
Tabela 6.6.3. Distribucija apsolutne relativne greške predviđanja specifične potrošnje energije.....	136
Tabela 6.6.4. Relativni značaj ulaznih promenljivih mikrofiltracije na smanjenje potrošnje energije u stacionarnim uslovima	140

UVOD

Mikrofiltracija, predstavlja jednu od značajnijih procesnih separacionih tehnika u hemijskom inženjerstvu koja poslednjih godina zamenjujući procese klasične filtracije postaje nezaobilazni korak u proizvodnji više industrijskih grana. Primena mikrofiltracije pored prehrambene industrije ima značajno mesto u petrohemiji, u farmaceutskoj industriji, za tretman otpadnih tokova u cilju regeneracije vrednih materijala, energije ili zaštite životne sredine. Razlog ekspanzije ovih sistema je zbog malih energetske zahteva, manjih gabarita u odnosu na pojedine industrijske linije, stvaranju male količine otpada, lake mogućnosti automatizacije i značajne sigurnosti sa aspekta bezbednosti.

Proces mikrofiltracije zavisi od velikog broja procesnih parametara (protok suspenzije, transmembranski pritisak, koncentracija napojne smeše, distribucija veličine čestica, i dr.) tako da projektovanje ove tehnološke operacije zahteva detaljno poznavanje njenih karakteristika prvenstveno fenomena koji se događaju u blizini površine membrane. Tokom procesa mikrofiltracije, vremenom, neminovno dolazi do opadanja fluksa permeata zbog taloženja odnosno akumulacije čestica na površini membrane, ali i adsorpcije manjih čestica i makromolekula na zidove pora. Opadanje fluksa permeata je osnovna posledica povećanja operativnih troškova uzrokovano povećanom potrošnjom energije, dodatnim radom na održavanju, potrebom za zaustavljanjem procesa i čišćenjem čija učestalost utiče na radni vek membrane i konkurentnost procesa mikrofiltracije u praksi. Prljanje membrana je složena funkcija različitih fizičkih, bioloških i hemijskih faktora za koje još ne postoje jedinstveni naučni stavovi. Smanjenje prljanja, može se delimično izbeći primenom raznih tehnika (modifikacijom površine membrane, primenom elektromagnetnih i mehaničkih metoda, promenom hidrodinamičkog režima u membrani i modulu), ali se ne može sprečiti. S toga je pronalaženje modela koji na adekvatan način simuliraju ponašanje sistema, opisuju zavisnosti pojedinih parametara procesa i fenomena koji se dešavaju blizu površine membrane ključno za optimizaciju, simulaciju i veću komercijalnu upotrebu ovih sistema.

Direktna istraživanja na velikim i složenim proizvodnim sistemima po pravilu zahtevaju puno resursa i vremena, a ponekad su i teško izvodljiva, naročito u fazi njihovog planiranja, projektovanja, uvođenja u rad i optimizacije. Predstavljanje realnog sistema modelom na kom će se vršiti istraživanja, a zatim dobijeni rezultati preneti na realni sistem ključni je deo predviđanja ponašanja tehnoloških procesa. Uzimanjem u obzir velikog raspona fenomena za predviđanje fluksa permeata do sada je razvijeno više modela (teorijskih, empirijskih i semiempirijskih).

Međutim, do sada predloženi modeli uz postojanje značajnih varijacija u pristupima, samo utvrđuju specifične pojave, tako da na ovom polju nisu dali zadovoljavajuće rezultate. Teorijski modeli, sastavljeni od niza kompleksnih matematičkih jednačina sa velikim brojem promenljivih, uglavnom se ne mogu rešiti postojećim metodama ili iziskuju izuzetno mnogo vremena i resursa. Takođe, kako su mehanizmi prljanja membrane i uticaj ključnih faktora na stvaranje filtracione pogače na površini membrane još uvek nejasni ili prilično kontraverzni, projektovanje ovakvih teorijskih modela uslovljeno je usvajanjem niza pretpostavki. Sa druge strane, empirijskim modelima, iako su vrlo precizni često fali dovoljno opštosti, pa se mogu primeniti samo na određene vrste napojnih smeša pod definisanim uslovima (Vivier i Mehablia, 2012). Kod semi-teorijskih modela se ne zahteva detaljno poznavanje zakonitosti koje vladaju u sistemu, međutim, promena samo jednog parametra u procesu projektovanja menja karakteristike modela, pa su korisna samo predviđanja vezana za konkretan slučaj za koji je model razvijen.

Inicijalna istraživanja sprovedena u svetskim okvirima, potvrđuju primenljivost neuronskih mreža u modelovanju mikrofiltracijskih i drugih membranskih separacionih procesa. Modeli neuronskih mreža, prema današnjim saznanjima, omogućavaju aproksimaciju procesnih funkcija sa veoma povoljnim rezultatima pošto ispoljavaju izvesnu toleranciju na nepreciznosti i neodređenosti tehnoloških parametara pri opisu realnih sistema, te nude prilagodljivija i robusnija rešenja za probleme modelovanja složenih nelinearnih sistema sa velikim brojem međusobno povezanih parametara kakav je proces mikrofiltracije kultivacionih tečnosti. Ipak, informacije dobijene iz literaturnih izvora govore u prilog konstataciji da su istraživanja na modelovanju mikrofiltracije kultivacionih tečnosti još uvek u početnoj fazi i da mnoga pitanja još uvek ostaju otvorena. Prema tome, problematika modelovanja procesa mikrofiltracije kultivacionih tečnosti neuronskim mrežama predstavlja oblast koja je vrlo zahvalna za dalja istraživanja.

1. CILJ ISTRAŽIVANJA

Osnovni zadatak i istraživački izazov disertacije je bilo ispitivanje mogućnosti primene koncepta neuronskih mreža za modelovanje mikrofiltracije kultivacionih tečnosti u različitim uslovima (u uslovima postupka ugušćivanja, u uslovima recirkulacije napojne suspenzije, u uslovima primene dvofaznog toka i kombinovanog postupka primene promotora turbulencije i dvofaznog toka). Cilj je da se na osnovu rezultata eksperimenta uoče i definišu određene zakonitosti u ponašanju veštačkih neuronskih mreža. Na osnovu uočenih zakonitosti biće urađena analiza uticaja procesnih parametara (transmembranski pritisak, protok tečnosti i vazduha i vreme filtracije) na pad fluksa permeata. Analiza treba da posluži za razvoj dinamičkog modela zasnovanog na konceptu neuronskih mreža koji će na adekvatan način simulirati ponašanje sistema i opisati zavisnosti između pojedinih parametara procesa.


Kako bi se ispunio navedeni osnovni cilj istraživanja u okviru ove doktorske disertacije, definisani su i specifični ciljevi istraživanja. Jedan od tih ciljeva predstavlja uspešnost razvijenih modela pada fluksa permeata tokom postupka mikrofiltracije u sistemima bez i sa primenjenim metodama za poboljšanje fluksa i njihove kombinacije, kao i razvoj modela kojim bi se objedinili eksperimentalni rezultati u cilju dobijanja jedne jedinstvene neuronske mreže za simulaciju svih metoda poboljšanja fluksa. Dodatni cilj predstavlja i razvoj modela neuronskih mreža za procenu efikasnosti poboljšanja fluksa usled primene metoda poboljšanja fluksa permeata u stacionarnim uslovima čija će se adekvatnost proveriti sa energetskog stanovišta.

Obzirom da je postupak mikrofiltracije kompleksan jer su pojave u procesu veoma složene tako da se ne mogu jednostavno predstaviti u formi matematičkih jednačina disertacija treba da dokaže hipotezu da razvijeni modeli veštačke neuronske mreže mogu sa visokom tačnošću predvideti promene realnih vrednosti fluksa permeata u veoma dinamičnim uslovima mikrofiltracije kultivacionih tečnosti. Ovakav pristup treba da produbi znanja o mogućnosti primene koncepta neuronskih mreža mikrofiltracije kompleksnih smeša poput kultivacionih tečnosti i da doprinos sa praktičnog inženjerskog stanovišta primene modela neuronske mreže kao važnog alata prilikom projektovanja, proračuna i optimizacije realnih mikrofiltracionih sistema.

PREGLED LITERATURE

2. Membranski separacioni procesi

Membranski separacioni procesi se temelje na postupku filtracije višekomponentne smeše kroz polupropustljivu membranu koja ima sposobnost propuštanja, odnosno zadržavanja čestica prema njihovoj veličini i specifičnim karakteristikama. Polupropustljiva membrana predstavlja barijeru, "tanak film koji razdvaja dva fluida omogućavajući selektivni prolaz odgovarajućih hemijskih vrsta iz jednog fluida u drugi pod dejstvom pogonske sile" (Baker, 2004). Transportom fluida tokom membranske separacije dobijaju se filtrat (permeat) koji prolazi kroz membranu, osiromašen komponentom koja se odvaja i koncentrat (retentat) bogatiji komponentom koja se razdvaja (slika 2.1.1.).



Slika 2.1.1. Tok fluida u procesu membranske separacije (Baker, 2004)

Membranski separacioni procesi mogu se grubo klasifikovati prema kriterijumu inicijalne pogonske sile na osnovu koje dolazi do razdvajanja komponenata napojne smeše. Pogonska sila koja dovodi do transporta fluida kroz polupropustljivu membranu može biti: gradijent pritiska, gradijent koncentracije, gradijent hemijskog ili električnog potencijala i dr.

Pored prethodno navedenog kriterijuma membranski separacioni procesi mogu se klasifikovati i prema mehanizmu separacionog procesa, veličini čestica koje se zadržavaju na membrani, i prema tome da li je željeni proizvod retentat ili permeat. Prema separacionom mehanizmu razlikuju se:

1. procesi kod kojih je mehanizam separacije baziran na propuštanju tzv. filtracija kroz sito,
2. procesi kod kojih je mehanizam separacije zasnovan na različitoj difuzivnosti kroz membranu i različitom afinitetu komponenti napojne smeše prema membrani i
3. procesi kod kojih je mehanizam separacije zasnovan na razlici u naelektrisanju molekula.

Kod separacionih procesa zasnovanih na propuštanju pogonska sila je razlika pritiska. U ove procese ubrajaju se mikrofiltracija, ultrafiltracija i nanofiltracija. Mikrofiltracija uključuje korišćenje poroznih membrana čiji su prečnici između 50 i $1 \cdot 10^3$ nm (Jokić, 2012). Kod ultrafiltracije proces separacije se odvija mehanizmom tzv. molekulskog prosejavanja, a uključuje korišćenje mikroporoznih membrana čiji su prečnici između 1 i 100 nm (Mulder, 1996). Nanofiltracija je proces kojim se zadržavaju čestice napojne smeše na porama veličine od 1 do 10 nm (Jokić, 2012).

U separacione procese zasnovane na različitoj difuzivnosti kroz membranu i različitom afinitetu komponenta napojne smeše prema membrani ubrajaju se reversna osmoza, separacija gasova, dijaliza i perisparavanje. Pogonska sila na osnovu koje dolazi do razdvajanja komponenta napojne smeše kod procesa reversne osmoze i separacije gasova je razlika pritiska. Osmoza je prirodan proces u kom molekuli prolaze kroz polupropustljivu membranu u pravcu od razblaženijeg rastvora ka koncentrisanijem sve dok se koncentracije ne izjednače. Razlika pritiska u ovim sistemima je jednaka osmotskom pritisku. Reversna osmoza je proces suprotan procesu osmoze kod kog transport komponenti napojne smeše kroz membranu nije rezultat prodiranja kroz pore nego difuzije kroz upražnjena mesta u strukturi molekula membrane. U ovim sistemima spoljni pritisak je veći od osmotskog tako da molekuli prolaze u pravcu od koncentrovanijeg ka razblaženijem rastvoru. Reversna osmoza se naziva i hiperfiltracija zbog velike razlike pritiska koja je potrebna za odvijanje procesa (Šećerov-Sokolović i Sokolović, 2002). Mikrofiltracija, ultrafiltracija, nanofiltracija i reversna osmoza su veoma slični procesi koji se razlikuju samo po veličini separisanih čestica i vrsti upotrebljenih membrana. Za razliku od reversne osmoze i separacije gasova dijaliza i perisparavanje predstavljaju procese u kojima do separacije komponenti napojne smeše dolazi usled gradijenta koncentracije tokom difuzije kroz membranu.

U separacione procese kod kojih se difuzija komponenti napojne smeše kroz membranu zasniva na razlici u naelektrisanju ubraja se elektrodijaliza. Kod ovog procesa pod dejstvom električnog polja i usled postojanja potencijalne razlike jona, dolazi do kretanja anjona iz

dijalizirajuće tečnosti kroz anjonsku selektivnu membranu ka anodi, dok se katjoni propušteni od strane katjonske izmenjivačke membrane kreću ka katodi.

Na osnovu širokog spektra nabrojanih tipova mehanizama membranskih separacionih procesa može se reći da membrana nije pasivna već funkcionalna barijera transferu čestica, čija propusnost zavisi od fizičko-hemijskih interakcija između membrane i komponenti napojne smeše. Stoga je pri odabiru bitno poznavati vrste i osobine membrana kako bi se zadovoljili unapred definisani zahtevi za njihovu upotrebu.

Efikasnost membrane određena je njenom selektivnošću i protokom kroz membranu. Selektivnost membrane predstavlja sposobnost membrane da vrši separaciju različitih komponenti, a obično se definiše kao odnos permeabilnosti komponenata ili kao odnos difuzivnosti komponenata koji prolaze kroz membranu. Brzina kojom jedna komponenta prolazi kroz membranu predstavlja permeabilnost te komponente.

Membrane se izrađuju u širokom spektru oblika: ravne, cilindrične, kapilarne ili u obliku šupljih vlakana, kao i od različitih vrsta materijala: keramike, stakla, polimera, metala i metalnih oksida, a mogu biti i tečnost ili gas. Broj pora po jedinici površine membrane, njihov oblik i konfiguracija mogu znatno varirati, a to ima uticaj na produktivnost procesa. One mogu biti porozne ili neporozne, homogene (izrađene od jedne vrste materijala) ili heterogene strukture, odnosno kompozitne, simetrične i asimetrične.

Kako bi se postigla ekonomičnost membranskog separacionog procesa membrane se povezuju u membranske elemente tzv. module. Osnovna uloga membranskog modula je obezbeđivanje zadovoljavajućeg razdvajanja komponenti napojne smeše, odnosno održavanje odgovarajućeg fluksa kroz membranu. Modul predstavlja najmanju jedinicu uređaja za membransku filtraciju koji sadrži membranu (ili membrane) i neophodnu prateću opremu. Uopšteno, modul se sastoji od membrane i kućišta u koje je ugrađena membrana. Kućište ima priključak za dovođenje napojne smeše, priključak za odvod retentata i permeata, razdelnike membrana i dr. Primenom membranskog modula omogućava se lakše čišćenje membrana, jednostavna zamena membrana u modulu, postižu niski troškovi energije, a takođe se zbog veće membranske površine po jedinici zapremine modula postižu i zadovoljavajući hidraulični uslovi. Modularni princip izrade uređaja za membransku separaciju omogućava jednostavnu promenu kapaciteta uređaja izmenom načina povezivanja modula ili njihovog broja.


Sve intenzivnija ulaganja u razvoj novih tehnoloških procesa i sintezu novih membranskih proizvoda rezultovala su pre svega selektivnijim karakteristikama membrana,

njihovon nižom cenom i mogućnošću primene u skoro svim tehnološkim procesima. S toga su razvijeni i različiti tipovi modula (sa ravnim membranama, kapilarni, cevni, spiralno namotani, moduli sa šupljim vlaknima).

2.1. Mikrofiltracija

Mikrofiltracija je danas jedan od najrasprostranjenijih membranskih separacionih procesa koji je razvijen za laboratorijske potrebe tokom dvadesetih i tridesetih godina 20. veka. Prva značajnija primena mikrofiltracije zabeležena tokom Drugog svetskog rata kao brza metoda za praćenje mikrobiološke kontaminiranosti pijaće vode (Baker, 2004). Međutim, tek sredinom 60-tih godina započinje uzlazni razvoj ovih sistema i njihova industrijska primena.

Proces mikrofiltracije je od svih membranskih separacionih procesa najbliži konvencionalnoj filtraciji. Veličina pora mikrofiltracionih membrana omogućava zadržavanje čestica promera između 0,1 i 10 μm , što ih čini pogodnim za separaciju raznih suspenzija i emulzija. Tokom mikrofiltracije razlikujemo dva režima proticanja napojne smeše: transferzalni i unakrsni pravac toka, odnosno razlikujemo statičku i dinamičku mikrofiltraciju (slika 2.2.). Kod postupka statičke filtracije membrana "pregrađuje" tok, a fluid struji upravno na površinu membrane. Koncentracija zadržanih komponenti u napojnoj smeši raste i akumulira se na površini membrane stvarajući filtracionu pogaču.



Slika 2.2.1. Šematski prikaz transferzalnog i unakrsnog režima proticanja napojne smeše (Catalina i sar., 2013)

Kod postupka dinamičke filtracije napojni fluid struji uzdužno po površini membrane, a permeat struji poprečno. Uzdužnim strujanjem napojnog fluida ispira se (čisti) površina membrane i na taj način se smanjuje polarizacija koncentracije i sprečava taloženje čestica na membrani.

Razvojem membrana za mikrofiltraciju dolazi do sve veće ekspanzije ovog procesa naročito zbog proizvodnje efikasnijih i jeftinijih membrana što dovodi do smanjenja investicionih i eksploatacionih troškova. Tokom mikrofiltracije (koja se odvija u opsegu razlike pritisaka od 10 kPa do 500 kPa) moguće je ostvariti relativno visok fluks permeata pri maloj razlici pritisaka, tako da su ove membrane i sa stanovišta produktivnosti znatno ispred ostalih (Baker, 2002). Iz tog razloga se procesi klasične filtracije sve češće zamenjuju mikrofiltracijom (Nunes i Peinemann, 2006). Najznačajnije primene mikrofiltracije su u analitičkim i drugim laboratorijima, a odnose se na upotrebu klasične statičke filtracije s mikrofiltracionim membranama u obliku jednokratnih filtera. U industriji se mikrofiltracija koristi za sterilizaciju i bistrenje različitih vrsta pića (pivo, vino, voćni sok) i farmaceutskih proizvoda, pri proizvodnji tzv. „ultračiste“ vode gde se kombinuje sa reverznom osmozom, u bioreaktorima, u gorivim ćelijama, pri prečišćavanju otpadnih voda (Mulder, 1996, Nunes i Peinemann, 2006).

2.2. Postupci za poboljšanje fluksa permeata

Efikasnost membranskog separacionog procesa prvenstveno zavisi od kontrolisanja prljanja membrane pošto je to neminovan proces, ali je moguće primenom raznih tehnika ograničiti njegov uticaj. Kontrolisanje prljanja membrane je izuzetno važno naročito kod procesa mikrofiltracije, zato što u odnosu na ostale membranske separacione procese mnogo brže dolazi do pada fluksa permeata i blokiranja pora membrane (Baker, 2004). Smatra se da je pad fluksa permeata direktna posledica povećanog otpora proticanju permeata usled prljanja površine i porozne strukture membrane. Zaprljanost membrane se otklanja zaustavljanjem procesa i čišćenjem membrane fizičkim, hemijskim i biološkim sredstvima. Međutim, učestalost čišćenja obzirom da utiče na radni vek membrane predstavlja kritični ekonomski faktor (Bowen, 1995).

U literaturi se mogu pronaći različite preporuke kako kontrolisati i smanjiti prljanje membrane, preko manipulacije radnih parametara tokom procesa, pa sve do raznih predloga modifikacije samog sistema. Adekvatnim odabirom materijala membrane može se značajno

uticati na smanjenje fluksa permeata naročito ukoliko adsorbovane čestice na površini membrane utiču na redukciju efektivne veličine pora unutar membrane (Williams i Wakeman, 2002).

Uvođenjem dodatnih postupaka predobrade napojne smeše kako fizičkih (predfiltracija, centrifugisanje, pasterizacija radi uništavanja bakterija) tako i hemijskih postupaka (prilagođavanje pH, hemijsko taloženje, koagulacija ili flokulacija, korišćenje odgovarajućih hemikalija koje deluju kao antiskalanti ili dezinfekcionih sredstava) mogu se ukloniti čestice koje mogu izazvati veće prljanje membrane ili sprečiti taloženja čestica i makromolekula na površini membrane. Noviji pristupi uključuju uvođenje elektro-magnetnih i ultrazvučnih polja ili njihovih kombinacija mada nisu našli veću primenu zbog znatnog utroška energije, neminovne korozije elektroda, složenosti postupka i problema sa rastvaranjem jona u elektro i ultrasoničnom polju, kao i raznim tehničkim problemima ugradnje ultrazvučnih transmitera u membranske module (Williams i Wakeman, 2002, Ibeid i sar., 2013). Takođe, u literaturi je moguće pronaći preporuke o modifikaciji površine membrane za mikrofiltraciju kao efikasne metode za sprečavanje prljanja membrane (Paixao i sar., 2019, Homem i sar., 2019).

Kako bi se prevazišao problem opadanja fluksa permeata usled prljanja membrane najveći broj istraživanja je posvećen hidrodinamičkim metodama kojima se pospešuje nestabilno, nestacionarno ili turbulentno proticanje napojne smeše kroz membranski modul. Jedna od takvih metoda je i primena periodičnog povratnog ispiranja komprimovanim vazduhom ili inertnim gasom tokom procesa bistrenja voćnih sokova čime se izaziva nestabilno proticanje koje podiže nakupljeni talog sa membrane (Urošević i sar., 2018, Mondor i sar., 2000). Druge metode se odnose na upotrebu rotacionih modula i izazivanje vrtloženja usled proticanja kroz zakrivljene kanale (Wakeman i Williams, 2002), izazivanje pulzacionog proticanja napojne smeše (Jalilvand i sar., 2014), izazivanje turbulentog proticanja povećanjem brzine proticanja kod unaksne mikrofiltracije (Bellhouse i sar., 1994) kojima se omogućuje mešanje slojeva rastvora u blizini membrane, povratni transport zadržanih čestica i rastvorka od površine membrane ka masi rastvora, kao i poboljšanje prenosa mase na površini membrane.

Jedno od projektnih rešenja promene hidrodinamičkog režima u membranskom modulu jeste umetanje različitih promotora turbulencije. Funkcija promotora turbulencije je da usmeri fluid u pravcu drugačijem od glavnog toka npr. u radijalnom ili tangencijalnom pravcu izazivajući povećanje srednje brzine fluida i brzine smicanja na površini membrane.

Promotori turbulencije mogu biti statički (npr. namotane fiksirane šipke sa i bez pregrada, metalne rešetke, dodaci u obliku diska, prstena, konusa, sečiva (tzv. Koflo mikser), Kenics statički mešači) i dinamički (npr. fluidizovane čestice).

U literaturi se može pronaći veliki broj istraživanja koja su utvrdila izuzetnu efikasnost Kenics statičkog mešača u povećanju fluksa permeata tokom mikrofiltracije različitih napojnih suspenzija: pekarskog kvasca (Ogunbiyi i sar., 2007, Jokić i sar., 2010) obranog mleka (Krstić i sar., 2002), pšeničnog skroba (Ikonić i sar., 2012), voćnog soka (Pall i sar., 2008), bentonitne suspenzije (Liu i sar., 2010), kao i tokom tretmana otpadnih voda (Šereš i sar., 2018). Generalno se pokazalo da efikasnost statičkog promotora turbulencije zavisi od načina strujanja koji nastaje usled njegovog oblika i položaja unutar membrane, te da je povećanje fluksa permeata u velikoj meri povezano sa smanjenjem debljine filtracione pogače formirane na površini membrane (Jokić i sar., 2010). Upotreba statičkog promotora turbulencije je u velikoj meri ublažila i uticaj transmembranskog pritiska na debljinu naslaga na membrani (Liu i sar., 2012). Prednost statičkih promotora u odnosu na dinamičke ogleda se u jednostavnijem načinu ugradnje, manjim investicionim ulaganjima, nižim troškovima rada i održavanja jer nemaju pokretnih delova, veće otpornosti na habanje, kao i mogućnošću rada u širokom rasponu protoka i viskoziteta (Krstić i sar., 2002, Šereš i sar., 2012).

Značajan broj autora istraživao je i tehniku uduvavanja gasa u napojnu smešu kao jednostavnu metodu poboljšanja fluksa permeata (Pospišil i sar., 2004, Hwang i Hsu, 2009, Hwang i Chen, 2010). Naime, uduvavanjem gasa u napojnu smešu postiže se uspostavljanje dvofaznog toka kojim se utiče na hidrodinamičku nestabilnost proticanja unutar kanala membrane i prema tome na koncentracionu polarizaciju, uklanjanje formirane filtracione pogače koje rezultuje postizanjem većih vrednosti fluksa permeata. Efikasnost ovog procesa uveliko zavisi od geometrije membrane, napona smicanja, procesnih parametara (pritisak, temperatura, protok napojne smeše), kao i veličine mehurova gasa i načina raspodele faza, odnosno režima proticanja gas-tečnost (Hwang i Chen., 2010). U literaturi postoji nekoliko režima proticanja u zavisnosti od prividne brzine gasa koji utiču na brzinu smicanja na površini membrane: mehurasti tok, čepovit tok, prelazni tok, a pri velikim brzinama uočava se i anularni tok. Mehurasti režim toka se javlja pri malim brzinama gasa, a odlikuje se uniformnim veličinama mehurova koji teže da se koncentrišu u centru kanala membrane. Pri nešto većim brzinama gasa nastaje tzv. čepovit režim. Ovaj režim karakterišu veliki mehurovi koji se kreću velikim brzinama, zajedno sa takođe prisutnim malim mehurovima i uz izraženu koalescenciju. Prelazni režim predstavlja vezu između prethodna dva režima. Anularni režim

nastaje pri velikim brzinama kada gasna faza zauzima jezgro kanala membrane, dok tečna faza kontinualno protiče kao gust sloj uz zidove membrane. Cabassud i sar. (2001) su proučavajući uticaje hidrodinamičkih parametara proticanja gas-tečno na karakteristike filtracione pogače prilikom filtracije kroz membrane oblika šupljih vlakana zaključili da je razlika između režima proticanja određena vrednošću faktora injektovanja gasa (ε). Režim proticanja je mehurast kada je vrednost faktora injektovanja gasa (jednačina 2.1) manja od 0,2; u obliku velikih mehurova kada je $0,2 < \varepsilon < 0,9$; a postaje anularan za ε veće od 0,9 (Cabassud i sar., 2001):

$$\varepsilon = \frac{u_g}{u_g + u_L} \quad (2.1)$$

gde su: u_g i u_L superkritične brzine proticanja gasa i tečnosti, redom.

Pored tehnike uduvavanja gasa u napojnu smešu takođe su interesantna istraživanja kombinacije hidrodinamičkih metoda za poboljšanje fluksa permeata. Derradji i sar. (2000) su procesom injektovanja vazduha u prisustvu promotora turbulencije tipa Sulzer tokom ultrafiltracije smeše alginata i polimera povećali vrednosti fluksa permeata za 180%. U istraživanju unakrsne ultrafiltracije emulzije ulja i vode koje su sprovedi Vatai i sar. (2007) otkriveno je da upotreba statičkog mešača i dvofaznog toka dovodi do značajnog povećanja vrednosti fluksa permeata. Korišćena je ZrO_2 jednokanalna membrana, sa srednjim prečnikom pora od 20 nm i Kenics statički mešač. Rezultati su pokazali da prisustvo statičkog mešača redukuje vreme zadržavanja napojne smeše u kanalu membrane dovodeći do visokog pada pritiska duž membrane i povećanja potrošnje energije, a da kombinacija statičkog promotora i uduvavanja gasa može ostvariti visoke vrednosti fluksa permeata pri relativno malom utrošku energije.

3. Modelovanje mikrofiltracije

Osnovna svrha modelovanja je da omogući efikasnu simulaciju modela u cilju istraživanja odvijanja stvarnih procesa u promenljivim okolnostima. S toga model u užem smislu predstavlja opis nekog sistema, procesa, ili fenomena, koji uzima u obzir poznata, kao i pretpostavljena svojstva.

Mikrofiltracija zavisi od velikog broja procesnih parametara kao što su transmembranski pritisak, brzina proticanja, koncentracija, distribucija veličine čestica i njihov oblik, kao i otpor sloja koji te čestice formiraju, površinskih sila, konstrukcionog materijala i veličine pora membrane, otpora same membrane proticanju čestica i dr. (Altmann i Rippergar, 1997). Osnovni indikator efikasnosti procesa mikrofiltracije predstavlja promena fluksa permeata tokom vremena do koje dolazi usled prljanja membrane. Do danas je za predviđanje fluksa permeata i mehanizma prljanja membrane tokom mikrofiltracije razvijeno više modela (teorijskih, semiteorijskih i empirijskih). Teorijski modeli zasnovani su na strukturalnom znanju o mehanizmu procesa i primeni odgovarajućih poznatih zakonitosti između procesnih veličina u vremenu ili prostoru. Sa druge strane empirijski modeli zahtevaju poznavanje samo osnovnih principa koji vladaju procesom, dok se odnosi između promenljivih veličina utvrđuju na osnovu merenja i posmatranja realnog sistema (Ghandehari i sar., 2011, Rezakazemi i sar., 2012).

3.1. Teorijski i semiteorijski modeli

Teorijski modeli se temelje na pretpostavci da se neki proces može opisati matematičkim formulama na osnovu prethodnih znanja o fizičkim i hemijskim zakonitostima koje vladaju tim procesom, kao i postavljanju fundamentalnih prirodnih zakona održanja mase, energije i količine kretanja (bilansne jednačine). Ovi modeli se predstavljaju sistemom diferencijalnih i/ili algebarskih jednačina kojima se utvrđuje tok odvijanja procesa za zadate početne uslove i promene ulaznih veličina (Curcio i sar., 2009, Lipnizki i Tragardh, 2001). Sa druge strane semiteorijski modeli integrišu svojstva teorijskih metoda sa empirijskim metodama. Semiteorijski model se razvija na osnovu teorijske analize u kojoj su parametri modela dobijeni na osnovu eksperimentalnih rezultata ili se dopunjuju upotrebom različitih empirijskih izraza ili pak konstanti kako bi se postigla što veća adekvatnost modela.

U dostupnoj literaturi nivo opisa teorijskih modela mikrofiltracije je ili makroskopski (koji posmatra sistem čestica kao celinu) ili mikroskopski (koji razmatra ponašanje jedne čestice tokom procesa) (Ripperger i Altman, 2002). Neki od makroskopskih pristupa opisa procesa mikrofiltracije su model koncentracione polarizacije (Zydney i Colton, 1986) i model disperzivnog transporta čestica (Ripperger i Altman, 2002), zasnovani na difuzionom modelu, koji predviđaju da fluks permeata kontroliše brzina povratnog transporta čestica sa površine membrane. Naime, tokom mikrofiltracije dolazi do konvektivnog prenosa mase ka membrani pod uticajem pritiska. Gradijent koncentracije koji pri tom nastaje izaziva difuzivno kretanje čestica suprotno konvektivnom transportu. To dovodi do formiranja sloja povećane koncentracije u graničnom sloju uz membranu u odnosu na koncentraciju u napojnoj smeši izazivajući koncentracionu polarizaciju i dodatan otpor prenosu mase kroz membranu. Ovo ponašanje je opisano takozvanom teorijom filma (Cheryan, 1986). Prema toj teoriji koncentracija u sloju filma je konstantna tako da se sa povećanjem razlike pritiska povećava i debljina sloja filma koji je čvrsto vezan za membranu, a ne fluks kroz membranu. Ripperger i Altman (2002), pod pretpostavkom da su oba transportna mehanizma (konvektivni transport čestica prema površini membrane i povratna difuzija) u stacionarnom stanju u ravnoteži, izvode makroskopski teorijski model fluksa permeata:

$$J = k \frac{C_M - C_P}{C_F - C_P} = \frac{D}{\delta} \ln \frac{C_M - C_P}{C_F - C_P} \quad (3.1)$$

Gde su: J – fluks permeata [$\text{L m}^{-2}\text{h}^{-1}$], δ – debljina polarizacijskog graničnog sloja [m], D – koeficijent difuzivnosti [m^2h^{-1}], C_M – koncentracija komponente na površini membrane [gL^{-1}], C_P – koncentracija komponente u permeatu [gL^{-1}], C_F – koncentracija napojne smeše [gL^{-1}].

Prema ovom modelu koeficijent masenog transfera k , predstavlja odnos između difuzionog koeficijenta i debljine sloja u kom dolazi do koncentracione polarizacije. Autori tvrde da su makroskopski modeli mikrofiltracije zasnovani na modelu difuzije često na samoj granici sa semiteorijskim i empirijskim modelima, jer smatraju da se difuzioni koeficijent koji integriše sve efekte interakcije čestica, hidrodinamike i difuzije uglavnom određuje empirijski.

Istorijski gledano, znatan broj istraživača pokušao je da u teorijske modele mikrofiltracije uvrsti različite mehanizme prljanja membrane i sugerirše da su hidrodinamika čestica, njihova difuzija i međusobna interakcija, kao i površinski efekti tri osnovna mehanizma koji utiču na proces mikrofiltracije. Tako su Hermia i sar. (1982), za opis procesa koji dovodi do začepljenja pora membrane razvili četiri modela statičke mikrofiltracije zasnovana na Darsijevom zakonu: kompletni model začepljenja pora koji pretpostavlja da će svaka čestica iz filtracione pogače začeptiti pore membrane, intermedijarni model koji pretpostavlja da će samo jedan deo čestica iz filtracione pogače začeptiti pore, standardni model koji pretpostavlja da će zapremina pora biti smanjena proporcionalno zapremini filtrata usled taloženja čestica na zidove pora i model filtracione pogače koji pretpostavlja da je specifična otpornost formirane filtracione pogače proporcionalna zapremini filtrata (tabela 3.1.1). Za razliku od statičke mikrofiltracije tokom unakrsne mikrofiltracije pojava napona smicanja na površini membrane značajno utiče na fenomen začepljenja pora membrane (Li i sar., 1998).

Tabela 3.1.1. Hermia (1982) i Field (1995) modeli blokiranja pora tokom mikrofiltracije

Model	Jednačina	Pretpostavka
Hermia model		
Kompletno blokiranje	$V = \frac{J_0}{k_{CB}} (1 - e^{-k_{CB}t})$	ne dolazi do akumulacije čestica, svaka čestica iz filtracione pogače će začeptiti pore membrane
Intermedijarni model	$V = \frac{J_0}{k_{IB}} \ln(1 + k_{IB}t)$	dolazi do akumulacije čestica i začepljenja membrane usled akumulacije čestica
Standardno blokiranje	$\frac{t}{V} = \frac{1}{J_0} + \frac{k_{SB}}{J_0} t$	depoziti čestica na zidove pora membrane smanjuju unutrašnji prečnik pora
Model filtracione pogače	$\frac{t}{V} = \frac{k_{CF}}{4J_0^2} V + \frac{1}{J_0}$	dolazi do zadržavanja čestica i formiranja filtracione pogače
Field model		
Model unakrsne mikrofiltracije	$-\frac{dJ}{dt} J^{n-2} = k(J - J^*)$	za model filtracione pogače $n = 0$, za model kompletnog blokiranja $n = 2$ i za intermedijarni model $n = 1$.

Gde su: J – fluks permeata [$L m^{-2}h^{-1}$], J_0 – početni fluks permeata [$L m^{-2}h^{-1}$], J^* – kritični fluks permeata [$L m^{-2}h^{-1}$], t – vreme [h], k_{CB} , k_{IB} , k_{CF} , k, n – konstante koje zavise od mehanizma prljanja membrane [].

Karakterističnost procesa unakrsne mikrofiltracije je da u određenom trenutku dolazi do uspostavljanja stacionarnog stanja, odnosno do ustaljivanja vrednosti fluksa permeata ispod koga prljanje membrane nema značajnog uticaja na proces. S toga Hermia model nije bio primenljiv na unakrsnu mikrofiltraciju. Uvođenjem teorije tzv. kritičnog fluksa (pojava da na početku procesa mikrofiltracije dolazi do početnog opadanja fluksa permeata usled brzog adsorbovanja i taloženja čestica napojne smeše na membrani, a zatim fluks dostiže određenu konstantnu vrednost) Field i sar. su 1995. modifikovali Hermia model i izveli osnovnu jednačinu opadanja fluksa sa vremenom tokom unakrsne mikrofiltracije (tabela 3.1.1).

Razvoj Hermia i Field modela prljanja membrane je veoma značajan pošto su ovi modeli poslužili mnogim istraživačima kao osnov za razvoj raznih teorijskih i semiteorijskih modela mikrofiltracije. Tako je Song (1998) razvio makroskopski model dinamičke filtracije koja se odvija u tri faze: faza naglog početnog pada fluksa, faza postepenog smanjenja fluksa i faza ravnotežnog stanja. Prva faza uzrokovana je otporom sloja čestica dovoljnim da izazove maksimalno začepljenje pora membrane. Nakon ove faze dolazi do postepenog smanjenja efektivnog prečnika pora membrane, stvaranja sloja gela i početak formiranja pogače što predstavlja drugu fazu otpora protoku permeata. U poslednjoj fazi formirana pogača na membrani pruža dodatni otpor protoku permeata što dalje utiče na smanjenje fluksa sve dok se ne postigne tzv. ravnotežna debljina sloja i uspostavi ravnotežno stanje. Model uključuje jednačinu vremenski zavisnog fluksa permeata tokom stvaranja filtracione pogače i blokiranja pora i jednačinu fluksa permeata u stacionarnom stanju (Song, 1998):

$$J = e^{-\alpha} \frac{\Delta P}{R_m} + (1 - e^{-\alpha}) \frac{(\Delta P - \Delta P_c)}{R_{bm}} \left(1 + \frac{2r_c (\Delta P - \Delta P_c)}{R_{bm}^2} \frac{C_0}{C_g}\right)^{-1/2} \quad (3.2)$$

$$J(t) = \begin{cases} \frac{1}{L} \left[\int_0^{x(t)} J_{eq}(x) dx + [L - X(t)] J(t) \right] & \text{pri } t \leq t_{ss} \\ 1,31 \left(D^2 \frac{\gamma}{L} \right)^{1/3} \left(\frac{C_g}{C_0} - 1 \right)^{1/3} & \text{pri } t \geq t_{ss} \end{cases} \quad (3.3)$$

Gde su: J – fluks permeata [$L \text{ m}^{-2} \text{ h}^{-1}$], J_0 – početni fluks permeata [$L \text{ m}^{-2} \text{ h}^{-1}$], J^* – kritični fluks permeata [$L \text{ m}^{-2} \text{ h}^{-1}$], ΔP – transmembranski pritisak [Pa], ΔP_c – kritični transmembranski

pritisak [Pa], α – koeficijent blokiranja izražen preko stepena blokiranja pora [], t – vreme [h], t_{SS} – vreme potrebno da se postigne stacionarno stanje na dužini L [h], R_m – otpor čiste membrane [m^{-1}], R_{bm} – otpor začepljene membrane [m^{-1}], r_C – specifični otpor pogače formirane na membrani [m^{-1}], D – koeficijent difuzivnosti [m^2h^{-1}], C_0 – koncentracija komponente u napojnoj smeši [gL^{-1}], C_g – koncentracija komponente u filtracionoj pogači [gL^{-1}], C_F – koncentracija napojne smeše [gL^{-1}], L – dužina pore membrane [m], γ – stepen smicanja [Nm^{-2}], x – rastojanje od početka filtracione pogače [m] i X – rastojanje od početka filtracione pogače do mesta gde počinje ravnotežno stanje [m].

U drugim makroskopskim teorijskim modelima unakrsne mikrofiltracije zasnovanim na difuziji usled smicanja (Li i sar., 1998, Hwang i sar., 2003) pretpostavlja se da povratni transport čestica od površine membrane ka masi rastvora raste sa porastom napona smicanja. Osnovna pretpostavka razvoja modela je konstantna debljina filtracione pogače u stacionarnom stanju.

Novija istraživanja baziraju se na modifikaciji kombinacije klasičnog hidrauličnog modela koji opisuje blokiranje pora (Koonani i Amirinejad, 2019), modelu zasnovanom na modelu ukupnog otpora koji opisuje ponašanje suspenzije čestica različitih dimenzija (Iritani i sar., 2014), kao i modelu koji uvodi koncept morfoloških svojstava membrane u opis procesa mikrofiltracije (Sanaei i sar., 2017).

Klasičan hidraulički model blokiranja pora zasnovan je na pretpostavci da sve čestice napojne smeše doprinose kompletnom i standardnom modelu začepljivanja pora (Hermia, 1982). Model zasnovan na modifikaciji Hermia modela blokiranja pora pretpostavlja da se samo jedan deo čestica napojne smeše taloži unutar zidova pora membrane, dok drugi deo čestica može izazvati začepljenje pora i formiranje pogače (Koonani i Amirinejad, 2019). Brzina taloženja čestica na unutrašnjim zidovima pore izvedena je iz kinetičke jednačine nultog reda:

$$\frac{dV_m}{dt} = K_{s0} A = K_{s0} 2\pi r \delta_m, V_m = \pi(r_0^2 - r^2)\delta_m \quad (3.4)$$

Gde su: A – površina membrane [m^2], K_{s0} – konstanta blokiranja pora [h^{-1}], r – prečnik pore membrane [m], ΔP – transmembranski pritisak [Pa], ΔP_c – kritični transmembranski pritisak [Pa], δ_m – debljina membrane [m], t – vreme filtracije [h] i V_{in} – zapremina deponovanih čestica [m^3].

Značajan broj autora smatra da veličina čestica u napojnom rastvoru predstavlja važan faktor koji utiče na dominantan mehanizam transporta čestica kroz membranu. Proporcionalan brzini smicanja i veličini čestica je mehanizam hidrodinamičke difuzije izazvane smicanjem. Prema ovom mehanizmu dolazi do međusobne interakcije čestica koje se sudaraju, izazivajući nasumično kretanje. Naime, submikronske čestice imaju visoke koeficijente difuzije, pošto osciluju i kreću se haotično u svim pravcima i smerovima, tako da difuzija kao posledica Braunovog kretanja predstavlja najefikasniji transportni mehanizam (Liu i sar., 2015). Braunova difuzija nezavisna je od brzine smicanja i opada sa povećanjem veličine čestica (Tiwari i sar., 2009). Kao rezultat vučne sile (koja odnosi nataložene čestice dalje od površine membrane) na odnošenje nataloženih čestica sa površine membrane ili iz sloja formirane filtracione pogače utiču i bočne sile podizanja. Rezultujuća brzina podizanja čestica proporcionalna je kvadratu brzine smicanja i kubu veličine čestice (Liu i sar., 2015), a površinski transport čestica se linearno povećava povećanjem brzine smicanja i prečnika čestica. Zbog ovog efekta, manje čestice će se mnogo lakše pričvrstiti na sloj filtracione pogače. Uzimajući u obzir uticaj sila povratne difuzije čestica, kao što su bočna sila podizanja, sila smicanja, sila odbijanja, Van der Vals-ove sile, Braunove difuzije i gravitacione sile razvijeni su razni mikroskopski teorijski modeli procesa mikrofiltracije. Model superpozicije čestica pokazuje da adhezivne sile uzrokovane Van der Vals-ovim silama, elektrostatičkim interakcijama i silom trenja dominantno utiču na čestice koje se talože na površinu membrane (Altmann i Ripperger, 1997). Stoga je kod ovog modela taloženje manjih čestica na pore membrane uglavnom nepovratan proces, a sile povratne difuzije utiču samo na velike čestice, aglomerate i fragmente sloja formirane filtracione pogače. Predstavljeni model pokazuje da na nestacionarno stanje utiče celokupna raspodela veličine čestica, dok dostizanje stacionarnog stanja isključivo zavisi od čestica male veličine (Altmann i Ripperger, 1997).

Model tangencijalnog transporta čestica (Knutsen i Davis, 2006) objašnjava pojavu frakcionog taloženja i obrtne brzine čestica. Autori su razmatrali ponašanje glatke sferne

čestice koja se kreće duž grube, hrapave površine membrane usled delovanja sile smicanja, viskoziteta fluida pri malom Rejnoldsovom broju zavisnom od veličine čestice.

Rezultati modela su potvrđeni eksperimentima unaksne mikrofiltracije suspenzije ćelija kvasca i čestica lateksa veličina 4,5 μm, 10 μm i 20 μm na membrani izrađenoj od aluminijskog oksida. Primarni parametar u modelu je bezdimenzioni fluks permeata definisan kao odnos između brzine protoka fluida koji teče normalno na površinu membrane i karakteristične brzine smicanja. Utvrđeno je da će se, pri određenom fluksu permeata, sferna čestica zalepiti na površinu membrane samo kada naiđe na element hrapavosti viši od njene kritične visine. Autori smatraju da razvijeni dinamički model predviđa ne samo uslove potrebne za taloženje čestica nego i prosečnu tangencijalnu obrtnu brzinu čestica koje su u interakciji sa površinom membrane.

Sa druge strane model linearnog transporta čestica u jednačine modela uvrštava difuzivnost čestica izazvanih smicanjem (Ben Hassan i sar., 2013). Prema ovom modelu masa deponovanih čestica po jedinici površine u vremenu t na položaju x duž membrane jednaka je konvektivnom protoku po jedinici zapremine. Autori su pri razvoju modela zanemarili uticaj Braunove difuzije zbog primene modela na relativno velike čestice (prečnika većeg od 4,8 μm). Osnovna pretpostavka modela je da ukupan otpor prljanja membrane zavisi od položaja duž membrane koji se može izraziti preko hidrauličnog otpora (jednačina 3.6) izraženog preko modifikovane Kozeny-Carman-ove jednačine, pri čemu je otpor unutrašnjeg prljanja membrane zanemaren zbog velike razlike u veličini pore membrane i veličine čestice. Prema ovom modelu brzina komponenti u normalnom smeru na granici kontaktne površine tečnost/pogača se može izraziti sledećom jednačinom:

$$u_n^c(x) = \frac{\frac{dm_p}{dt}}{\rho_p(1-\varepsilon_C)} \quad (3.5)$$

$$R_C = \frac{150E_C(1-\varepsilon_C)^2}{d_p^2\varepsilon_C^3} \quad (3.6)$$

Gde su: u – brzina čestice na interfejsu fluid-pogača [mh^{-1}], m_p – masa deponovanih čestica [kg], t – procesno vreme [h], ρ_p – gustina čestice [kgm^{-3}], ε_C – poroznost pogače [], R_C – hidraulički otpor čestica sloja pogače, d_p – prečnik čestice [m] i E_C – debljina pogače [m].

Model razvijen od strane Tivari i sar. (2009) zasniva se na konceptu međufaznih sila koje se javljaju između tečnosti i dispergovanih čestica uz pretpostavku izotermnih uslova. Autori su utvrdili da je difuziona sila indukovana smicanjem proporcionalna veličini lokalnog napona smicanja i koncentracionog gradijenta:

$$M_{SI} = -C_{SI} \left| \underline{\tau}_1 \right| \nabla \alpha_p \quad (3.7)$$

Gde su: M_{SI} – difuziona sila izazvana smicanjem [N], C_{SI} – bezdimenzioni koeficijent disperzije izazvan smicanjem [], τ_1 – veličina lokalnog smicajnog napona tečnosti [Nm^{-2}] i $\nabla \alpha_p$ – gradijent zapreminske koncentracije frakcije čestica.

Autori naglašavaju da je koeficijent disperzije izazvan smicanjem u modelu jedinstvena funkcija zapremine frakcije čestica. Kao što se može videti iz jednačine (3.7) difuziona sila indukovana smicanjem deluje u smeru smanjenja gradijenta koncentracije. Na osnovu pretpostavljene koncentracije frakcije čestica izvršena je validacija semiteorijskog modela uz pretpostavku monodisperzne raspodele čestica, a oblast u blizini poroznog zida u kojoj dolazi do drastične promene frakcija čestica tumači se kao debljina polarizovanog sloja čestica. Nakon razvoja i validacije modela autori su izveli i numeričku simulaciju radi ilustracije primene ovog modela na mikrofiltraciju dvofaznih sistema.

Razvijanjem mikroskopskog modela mikrofiltracije zasnovanog na hidrodinamičkoj difuziji izazvanoj smicanjem bavili su se i Liu i sar. (2015). Oni su izvršili iscrpne numeričke simulacije kako bi razjasnili kompleksnu zavisnosti između lokacije čestica, njihove veličine, proporcionalnog odnosa dimenzija pora membrane i Rejnoldsovog broja. Autori ukazuju da čestice mogu, suprotno od očekivanog, migrirati kretanjem duž strujnica do specifičnih ravnotežnih položaja pri ograničenom Rejnoldsovom broju brzine smicanja, što je rezultat nelinearnog efekta inercije fluida. Generalno, inercijalna migracija čestica pripisuje se ravnoteži efekta podizanja izazvanog gradijentom brzine smicanja nastalog zbog zakrivljenosti toka koji česticu usmerava ka zidu pore membrane i efekta podizanja izazvanog uticajem zida pore membrane koji gura česticu dalje od zida. Model opisuje raspodelu sila unutar pravougaonog profila pore membrane koje deluju na migraciju jedne čestice i analizira kako distribucija čestica zavisi od njihove veličine. Autori su utvrdili da se broj i lokacija ravnotežnog položaja na osnovu numeričkih simulacija putanje zasniva na

dvostepenoj migraciji čestica. Rezultati modela ukazuju da kritični Rejnoldsov broj pri istom odnosu proporcija pore membrane opada sa veličinom čestica.

Mikroskopska teorijska istraživanja vršena radi predviđanja taloženja čestica i rasta sloja pogače na membrani tokom dinamičke unaksne mikrofiltracije čestica cirkonijum oksida rezultovala su razvojem modela kritičnih veličina čestica zasnovanom na analizi sila koje deluju na jednu česticu (Pan i sar., 2015). Model je uključio uticaj sile povlačenja u radijalnom smeru, sile bočnog dizanja, sile smicanja i Braunove difuzione sile u smeru taloženja, Van der Vals-ove sile u obodnom (perifernom) smeru, a privlačne sile unakrsnog proticanja i Van der Vals-ove sile u aksijalnom smeru. Kao reprezentativne promenljive koje utiču na variranje kritične veličine čestica sa fluksom permeata izabrani su brzina unakrsnog protoka i temperatura napojne smeše. Rezultati modela su pokazali da je kritična veličina čestica u radijalnom smeru dominantan faktor koji utiče na taloženje čestica i formiranje sloja pogače, dok se uticaj temperature napojne smeše može zanemariti. Takođe je utvrđeno da čestice deponovane duž perifernog zida membranskog modula nisu ravnomerno raspoređene, dok je dinamički sloj formirane pogače deblji na dnu membranskog modula od sloja formiranog sa strane i na vrhu zbog gravitacione sile. Pri datom transmembranskom pritisku i koncentraciji napojne smeše debljina ovog sloja se smanjivala usled povećanja brzine protoka. Autori smatraju da je regulisanjem brzine protoka moguće postići ujednačenu debljinu formirane pogače. Rezultati simulacije su pokazali da povećanje transmembranskog pritiska dovodi do formiranja tankog, gustog sloja pogače, ali ne utiče na njegovu uniformnost, dok je niska koncentracija napojne smeše rezultovala formiranjem tanjeg i ujednačenijeg sloja pogače.

Teorijski modeli mikrofiltracije rezultovali su strukturalnim razumevanjem procesa, naročito pošto se razvojem ovih modela dolazi do novih saznanja o samom procesu što poboljšava tehnike upravljanja mikrofiltracionim sistemima. Međutim, ovi modeli sadrže veliki broj promenljivih tako da je za rešavanje niza kompleksnih jednačina neophodno uvođenje brojnih pretpostavki koje pojednostavljaju model. Semiteorijskim pristupom razvoja modela mikrofiltracije pokušala se pojednostavniti složenost teorijskih modela i kompleksnost broja parametara koje je potrebno utvrditi.

Semiteorijski hidraulični model konvektivnog protoka opisuje uticaj debljine pogače mikrofiltracionog modula na fluks permeata u stacionarnom stanju pod konstantnim transmembranskim pritiskom (Wang i sar., 2009). Model zasnovan na masenom bilansu izveden je na osnovu Darsijeovog zakona koji opisuje protok fluida kroz poroznu sredinu i

Hagen-Poiseuille–ove jednačine konvektivnog protoka kroz cilindričnu poroznu membranu, uz pretpostavku da je brzina kojom se debljina pogače povećava proporcionalna brzini kojom se čestice fluida dovode na površinu membrane umanjenom za brzinu kojom se čestice odnose sa površine membrane usled unakrsnog proticanja proporcionalnu Reynoldsovom broju:

$$\frac{d\delta(x)}{dx} = \frac{AC_b}{J_0} J(x) - K\zeta(x)^n \delta(x) \quad (3.8)$$

Gde su: C_b – koncentracija napojne smeše [kgm^{-3}], $J(x)$ – lokalni fluks permeata na rastojanju x membranskog modula [$\text{m}^3\text{m}^{-2}\text{h}^{-1}$], J_0 – početni fluks na ulazu u membranski modul za $x = 0$ i $t = 0$ [$\text{m}^3\text{m}^{-2}\text{h}^{-1}$], $\zeta(x)$ – brzina smicanja zida membrane na rastojanju x membranskog modula [Lh^{-1}], $\delta(x)$ – debljina pogače na rastojanju x membranskog modula [m], A – koeficijent brzine povećanja debljine pogače duž membrane u jedinici koncentracije napojne smeše [m^3kg^{-1}], x – rastojanje od ulaza u membranski modul [m], K – koeficijent [$(\text{s}^{-1})^n\text{m}^{-1}$] i n – konstanta koja se određuje metodom probe i greške.

Autori su validaciju modela izveli eksperimentalno mikrofiltracijom suspenzije kvasca na polivinildien fluoridnom membranskom modulu filtracione površine $0,3 \text{ m}^2$ sa veličinom pora od $0,1 \mu\text{m}$. Apsolutna vrednost relativne greške modela u odnosu na rezultate dobijene eksperimentom je iznosila manje od 7%.

Model obnovljive površine ima potencijal za realniji opis prenosa mase suspendovanih čvrstih čestica zbog toga što uzima u obzir slučajne, hidrodinamičke impulse koji se mogu generisati na površini membrane (npr. zbog hrapavosti membrane ili upotrebe promotora turbulencije) u poređenju sa postojećim modelima (npr. model filma i graničnog sloja), koji ne uzimaju u obzir slučajnu i nestabilnu strukturu blizu zida membrane (Ben Hassan i sar., 2013). Autori navode tri vrste sila koje utiču na transport mase u blizini zida pore membrane: inercijalne sile izazvane hrapavošću membrane, vučne sile koje mogu stimulisati haotično kretanje fluida i u laminarnim i u turbulentnim uslovima protoka i sile uzrokovane "bočnom migracijom" koloidnih čestica i tečnih fluida koji dovode do fenomena "paradoksa fluksa". Uvrštavanjem modela klasične teorije formiranja pogače u model obnovljive površine autori naglašavaju da mogu na zadovoljavajući način predvideti fluks permeata i stvaranje filtracione pogače na površini membrane i u dinamičkim i u statičkim uslovima. Model obnovljive površine predstavlja fuks permeata sledećom jednačinom:

$$J_a(t_p) = J_0 \left(\frac{e^{S^*}}{1 - e^{-t_p^*}} \sqrt{\pi S^*} \left[\operatorname{erf}(\sqrt{S^* + t_p^*}) - \operatorname{erf}(\sqrt{S^*}) \right] \right) \quad (3.9)$$

Gde su: $J_a(t_p)$ – prosečan fluks permeata pri procesnom vremenu t_p^* [mh^{-1}], J_0 – početni fluks [mh^{-1}], S^* – stepen obnovljivosti čestica na membranskoj površini određen eksperimentalno [] i t_p – procesno vreme [h].

Istražujući unakrsnu mikrofiltaciju fermentacione tečnosti tokom izdvajanja bioetanolu Hwang i Ku su 2014. razvili semiteorijski model ravnotežne sile koji uključuje brzinu unakrsnog protoka, transmembranski pritisak, fluks permeata, osobine filtracione pogače i koeficijent retencije zasnovan na Darsijevom zakonu. Autori pretpostavljaju da je sila trenja u tangencijalnom pravcu proporcionalna umnošku koeficijenta trenja i zbira vučne sile u pravcu filtracije i adhezivne sile, dok se uticaj sile gravitacije može zanemariti. Tokom eksperimenata mikrofiltracije suspenzije ćelija kvasca, etanola i glukoze autori su uočili da se ćelije kvasca teško filtriraju i da zbog specifičnih kompresabilnih karakteristika uzrokuju veoma kompaktnu strukturu filtracione pogače koja utiče na porast prosečnog specifičnog otpora filtracione pogače sa povećanjem transmembranskog pritiska. Ova zavisnost je data Tiller-ovom empirijskom jednačinom:

$$\alpha_{av} = A \Delta P^n \quad (3.10)$$

Gde su: α_{av} – specifični otpor filtracione pogače [mkg^{-1}], ΔP – transmembranski pritisak [Pa] i A, n – empirijski koeficijenti [].

Razvoj semiteorijskih modela omogućio je modifikaciju teorijskih modela eksperimentalno dobijenim promenljivama pogotovo u slučajevima kada se određeni fenomeni procesa ne poznaju dovoljno ili se ne pokoravaju poznatim fizičko-hemijskim ili biohemijskim zakonima. Ovakvi modeli su značajni kao osnova za dizajn membranskih modula pošto su sposobni da pokriju uticaje, npr. koncentracione polarizacije, pada pritiska permeata i prenosa toplote (Lipnizki i Tragardh, 2001).

3.2. Empirijski modeli

Empirijski pristup modelovanju ne zahteva poznavanje osnovnih principa koji upravljaju procesom nego je zasnovan na podacima prikupljenim iskustvenim posmatranjem, merenjima, zaključivanju ili simulacijama. Empirijski model se razvija na osnovu prikupljenih realnih podataka najčešće eksperimentom variranih odabranih parametara procesa i merenja željenih veličina na osnovu kojih se zatim utvrđuje korelacija između ulaznih i izlaznih promenljivih preko odgovarajućih matematičkih jednačina. Kod ovih modela najčešće se koriste razne statističke metode za utvrđivanje veze između zavisnih i nezavisnih promenljivih, kao i za procenu parametara koji figurišu prilikom aproksimacije odgovarajućih funkcionalnih zavisnosti (Hashemi i sar., 2012, Rezakazemi i sar., 2012, Luis i Van der Bruggen, 2015).

Neki od ovih modela razvijeni su za određivanje fluksa permeata: u zavisnosti od protoka, koncentracije napojne smeše i dužine kanala membrane mikrofiltracije različitih vrsta suspenzija (Mahenc i sar., 1986), u zavisnosti od Rejnoldsovog broja za mikrofiltraciju uljno-vodne emulzije (Nakashima i Shimizu, 1989), u zavisnosti od protoka, pritiska, koncentracije suspenzije ferihidroksida i prečnika pore membrane (Shishido i sar., 1988). Modifikacijom teorijskog modela statičke mikrofiltracije zasnovanog na Hagen-Poiseuille-ovoj jednačini laminarnog protoka Riesmeier i sar. (1989) razvili su empirijski model procene fluksa permeata tokom mikrofiltracije fermentacione suspenzije *Escherichia coli* i pekarskog kvasca. Navedene empirijski izvedene jednačine fluksa permeata prikazane su u tabeli 3.2.1.

Tabela 3.2.1. Pregled pojedinih empirijski koreliranih jednačina fluksa permeata

Autor	Korelaciona jednačina
Mahenc i sar. (1986)	$J_v = a_1 U^{a_2} C_b^{a_3} L^{a_4}$
Nakashima i Shimizu (1989)	$J_v = a R_e^{1,43-1,77}$
Riesmeier i sar. (1989)	$J_v = \frac{\Delta P A}{32 v_p (R_M + R_{MB})}; R_{MB} = P(\Delta p) \frac{v_k C^{0,42}}{\tau_\omega}$ $P(\Delta p) = P(\Delta p_1) \frac{1 + \Delta p_2 b}{1 + \Delta p_1 b}; b = 3,26810^{-3} [m^2 / N]$

Rezultati istraživanja ukazuju da se samo na osnovu određivanja faktora proporcionalnosti (koji zavisi od pritiska) u laboratorijskom eksperimentu i empirijskoj korelaciji otpora filtracione pogače ovaj jednostavni model mikrofiltracije može lako prilagoditi različitim mikrobnim suspenzijama ili membranskim materijalima. Međutim, zbog visokih vrednosti empirijski korelisanog specifičnog otpora model nije bio primenljiv i za unakrsnu mikrofiltraciju.

Za procenu performansi mikrofiltracionog sistema sa metalnom membranom Kim i Somiya (2003) razvili su empirijski model za predviđanje optimalnih operativnih uslova povremene ozonizacije koji dovode do smanjenja prljanja membrane zasnovan na tri operativna parametra (koncentracija (C), protok (Q) i vreme ubrizgavanja ozona (t)):

$$J_{srednji} = 0,41C^{0,35}Q^{0,08}t^{0,29} \quad (3.11)$$

Koeficijenti su određeni pomoću metode najmanjih kvadrata, a relativni uticaj pojedinih promenljivih procenjen je primenom višestruke regresione analize. Primenom navedene metode koncentracija ozona je najvažniji operativni parametar koji utiče na fluks permeata.

U protekle dve decenije, veliki broj razvijenih empirijskih modela usmeren je na procenu uticaja operativnih parametara na opadanje fluksa. U jednom od ovih istraživanja testirane su membrane različitih materijala i srednjih prečnika pora tokom prečišćavanja sirovog soja sosa (Li i sar., 2007). Razvijen je empirijski model za procenu otpora tokom unaksne mikrofiltracije kao funkcije transmembranskog pritiska, unakrsnog protoka i koncentracije ukupnih čvrstih supstanci. Ukupan otpor filtraciji, otpor usled koncentracione polarizacije, otpor filtracione pogače i unutrašnji otpor empirijski je korelisan polinomom i obrađen kompjuterskim programom za statističku obradu podataka kako bi se odredili korelacioni koeficijenti.

Na osnovu empirijskog modela pseudo-stacionarnog stanja koji je razvio Samuelson (1997) za mikrofiltraciju proteina surutke Rezaei i sar. (2014) uočavaju linearni odnos između Rejnoldsovog broja i limitirajućeg fluksa permeata prema eksperimentalnim rezultatima unaksne mikrofiltracije surutke membranama različitog materijala (polietersulfonat i polivinildienfluorid) srednje veličine pora od 0,45 μm , dok je odnos transmembranskog pritiska i fluksa permeata predstavljen polinomom drugog reda.

$$LimJ = (aP^2 + bP + c)R_e \quad (3.12)$$

Koeficijenti polinoma drugog reda utvrđeni su za svaku vrstu membrane. Relativno visoke vrednosti koeficijenta determinacije od 0,979 i 0,944 za svaku vrstu membrane, respektivno, ukazuju na adekvatno utvrđene koeficijente polinoma drugog reda. Autori su takođe ispitivali uticaj ukupnog otpora na fluks permeata. Eksperimentalni rezultati su pokazali da je dominantan otpor, otpor od reverzibilnog prljanja membrane uključujući koncentracionu polarizaciju i otpor uzrokovan formiranjem pogače. Predložen empirijski model važi za opseg pritiska od 0,5 do 2 bara i Rejnoldsov broj u opsegu od 750 do 2500.

Empirijski i poluempirijski model fluksa permeata u prisustvu električnog polja naizmenične struje razvijeni su za unakrsnu mikrofiltraciju zauljene otpadne vode (Behroozi i sar., 2019). To je prvi put da se istovremeno sa pojavom blokiranja pora modeluju i efekti električnog polja koji utiču na performanse mikrofiltracije. Model zasnovan na tri operativna parametra (početnom fluksu J_0^*), vremenu (t) i Clausius-Mossotti faktoru (K_1) razvijen na osnovu Hermia teorijskog modela:

$$\frac{J}{J_0^*} = \sqrt{\frac{1}{1 + K_1 t}} \quad (3.13)$$

Clausius-Mossotti faktor je funkcija frekvencije električnog polja zbog efektivne polarizabilnosti kapljica u emulziji koji zavisi od dielektrične konstante, konduktivnosti i ugaone frekvencije primenjenog električnog polja. Da bi se rešio sistem nelinearnih jednačina korišćena je posebno razvijena kompjuterska metoda. Poređenje predviđanja zasnovanih na empirijskom modelu sa eksperimentalnim rezultatima pokazuju maksimalnu grešku od 11,9%.

Empirijski i poluempirijski model fluksa permeata u uslovima uduvavanja vazduha u tok napojne smeše razvijeni su za mikrofiltraciju disperzije rastvora titanijun dioksida kroz tubularnu aluminijumsku membranu (Pospišil i sar., 2004). Autori su regresionom analizom bezdimenzionih brojeva ispitivali uticaj svih osnovih radnih uslova na fluks permeata i debljinu filtracione pogače. Dobijeni modeli su zasnovani na bilansu mase i Darsijevoj jednačini u kom je faktor proticanja gasa određen empirijski. Rezultati su pokazali da model adekvatno može povezati fluks permeata u stacionarnom stanju i hidrodinamičke uslove.

U istraživanjima koja su sproveli, Hwang i Hsu (2009) tvrde da je nestabilnost proticanja napojne smeše koju izaziva dvofazni tok posledica geometrije membrane, procesnih parametara (pritisk, temperatura, protok napojne smeše), graničnih uslova (napon

smicanja), načina raspodele faza (zapreminskog odnosa tečnosti i gasa, njihovih brzina proticanja, veličine i pokretljivosti mehurića i osobina fluida). Kao rezultat istraživanja razvijena su dva modela u kojima je empirijski određena korelacija između mase filtracione pogače, specifičnog otpora filtracione pogače i napona smicanja u blizini zida pore membrane u zavisnosti od režima proticanja. Napon smicanja pri mehurastom režimu proticanja gasne faze predstavljen je dvofaznim modelom proticanja gas-tečnosti, a za režim proticanja u obliku velikih mehurova sumom sile smicanja velikih mehurova u tečnosti koja nastaje usled naizmenične pojave mehurića i sile smicanja u filmu tečnosti oko mehurića gasa (Hwang i Hsu, 2009).

Empirijski modeli su jednostavni i omogućuju brzo dobijanje rezultata, ali se mogu primeniti samo na predviđanje ponašanja istog ili sličnog sistema u opsegu vrednosti parametara za koje je prethodno izvršena analiza i razvoj modela (Vivier i Mehablia, 2012). Ovi modeli nisu u stanju da se nose sa istovremenim fluktuacijama više od jedne ili dve ključne promenljive što ih čini teško primenljivim u industrijskim uslovima. Pojedini autori ipak smatraju da su ovi modeli korisni za preliminarnu procenu membrana, procesa i dizajna korišćenog modula, ali nisu pogodni za optimizaciju procesa i ne doprinose većem razumevanju promenljivih koje utiču na proces (Vivier i Mehablia, 2012).

3.3. Problemi u modelovanju membranskih separacionih procesa

Modelovanje mikrofiltracije nije jednostavan zadatak. Iako su osnovni principi procesa dobro poznati veoma je teško formirati prediktivni model koji bi se uspešno koristio za simulaciju rada u industrijskim uslovima. Razlog ovih poteškoća leži u postepenom prljanju membrane usled akumulacije čestica na površini membrane, ali i adsorpcije manjih čestica i makromolekula na zidove pora koje dovodi do značajnog smanjenja fluksa permeata tokom vremena (Krstić i sar., 2004). Osnovni problem predstavljanja mikrofiltracije matematičkim jednačinama leži u preciznom definisanju zakonitosti i mehanizama koji utiču na pojavu fenomena prljanja membrane.

Permeacija različitih hemijskih vrsta kroz poroznu mikrofiltracionu membranu rezultat je različitog intenziteta transporta koji zavisi od veličine transmembranskog pritiska, veličine molekula i koncentracije određene komponente u napojnoj smeši, kao i strukture same membrane. Pod idealnim uslovima proticanje fluida kroz mikroporozne membrane opisano je Hagen–Poiseuille-ovim zakonom koji pretpostavlja uniformnu raspodelu pora istih


veličina, laminaran protok kroz pore membrane, zanemarljivu koncentracionu polarizaciju i zaprljanost membrane, konstantnu gustinu fluida i dr. (Cheryan, 1986). Međutim, u slučaju velikih koncentracija i malih brzina proticanja napojne smeše koncentraciona polarizacija postaje značajna, pa se membranski proces ne može više adekvatno opisati Hagen-Poiseuille-ovim modelom. Razvojem teorijskih modela opisa procesa mikrofiltracije, naročito modela koji opisuju prljanje membrane došlo se do strukturalnog razumevanja procesa. Uvođenjem difuzionih principa zasnovanih na Darsijevom zakonu i modelu hidrauličkih otpora u makroskopske teorijske modele dobijaju se podaci o fenomenima prenosa mase kroz membranu. Sa druge strane, mikroskopski teorijski modeli su povezali mehanizam transporta i međusobne interakcije hemijskih vrsta, kao i njihove interakcije sa membranom koji važe za određene vrste i strukture membrane (Pan i sar., 2015). Međutim teorijski modeli, sastavljeni od niza kompleksnih matematičkih jednačina sa velikim brojem promenljivih, uglavnom se ne mogu rešiti postojećim metodama ili iziskuju izuzetno mnogo vremena i resursa, kao i neophodnost uvođenja određenih pretpostavki, što je i njihov osnovni nedostatak (Lipnizki i Tragardh, 2001). Ove modele, čak iako su vrlo precizni, neophodno je verifikovati poređenjem rezultata istraživanja dobijenih na modelu sa rezultatima dobijenim odgovarajućim eksperimentima.

Semiteorijski modeli su veoma korisni naročito kada se određeni fenomeni procesa mikrofiltracije ne poznaju dovoljno ili se ne pokoravaju poznatim fizičko-hemijskim ili biohemijskim zakonima. Međutim, promena samo jednog parametra u procesu projektovanja menja karakteristike modela, što zahteva ponovna merenja i modelovanja. S toga su ovi modeli pogodni za preliminarnu evaluaciju membrana i kada se donose neka predviđanja vezana za konkretan slučaj za koji je model razvijen.

Empirijski modeli mikrofiltracije uspeli su da postignu veću adekvatnost modela iako su zasnovani na poznavanju samo osnovnih principa koji vladaju procesom. Mogu se koristiti sa relativno velikom pouzdanošću predviđanja (mala greška predviđanja) ako se predviđa ponašanje istog ili sličnog sistema u opsegu vrednosti parametara za koje je prethodno izvršena analiza i razvoj modela. Međutim, empirijskim modelima često fali dovoljno opštosti, pa se mogu primeniti samo na određene vrste napojnih smeša pod definisanim uslovima (Vivier i Mehablia, 2012). Prljanje membrana je složena funkcija različitih fizičkih, bioloških i hemijskih faktora za koje još ne postoje jedinstveni naučni stavovi. Međutim, do sada predloženi modeli uz postojanje značajnih varijacija u pristupima, samo utvrđuju specifične pojave, tako da na ovom polju nisu dali zadovoljavajuće rezultate.

4. Koncept veštačkih neuronskih mreža

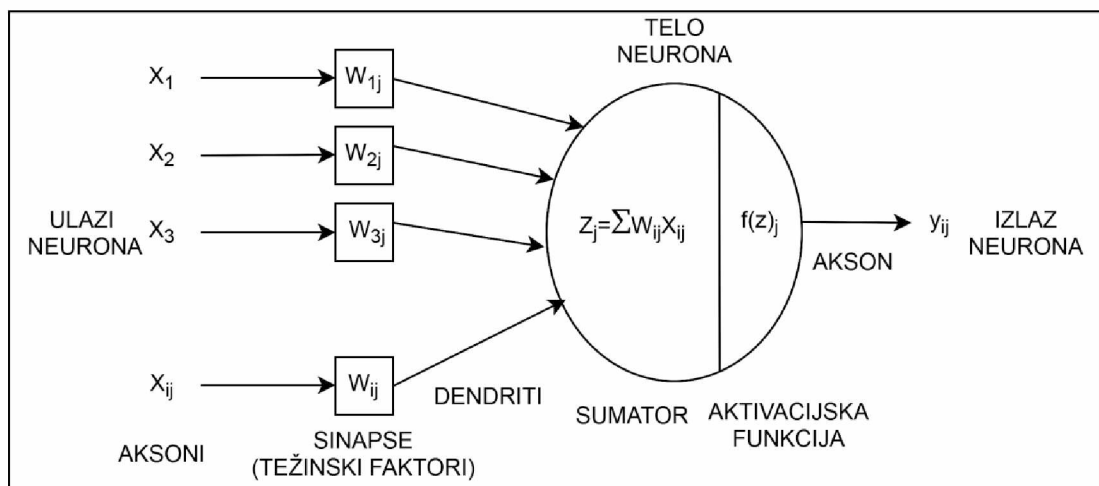
Osnovna ideja razvoja veštačkih neuronskih mreža je pokušaj oponašanja načina na koji ljudski mozak uči, klasifikuje i obrađuje razne podatke. Ljudski mozak se može predstaviti kao izrazito složen, nelinearan sistem koji sadrži oko 100 milijardi međusobno povezanih neurona. Svaki neuron sadrži telo ćelije (soma) koje sumira i upoređuje dolazeće signale iz mreže nervnih vlakana (dendrita) i zatim putem aksona propagira nastale informacije prema drugim neuronima preko tačke spajanja (sinapsi) aksona jedne ćelije i dendrita druge ćelije (slika 4.1.1).



Slika 4.1.1. Struktura biološkog neurona (Milenković, 1997)

Veštačke neuronske mreže su jednostavni element procesiranja dizajnirani tako da simuliraju mehanizam funkcionisanja bioloških neuronskih mreža (Milenković, 1997). Soma biološkog neurona zamenjuje se tzv. sumatorom koji predstavlja osnovnu jedinicu obrade podataka, ulogu dendrita preuzimaju ulazne promenljive u sumator, izlazna promenljiva sumatora je akson veštačkog neurona, a sinaptičke veze biološkog neurona s njegovom okolinom zamenjene su težinskim koeficijentima preko kojih se ostvaruje veza veštačkog neurona s njegovom okolinom. Strukturno neuronska mreža se može prikazati kao orijentisani graf čiji su čvorovi neuroni, a pravac protoka signala je prikazan strelicama (slika 4.2.1). Težinski koeficijent može biti nula, kada ne postoji veza neurona sa okolinom, pozitivan, ukoliko jedan neuron pobuđuje drugog ili negativan, ukoliko jedan neuron inhibira drugog. Veći težinski koeficijent uzrokuje i veći uticaj koji jedan neuron ima na drugog što

odgovara načinu na koji prave neuronske ćelije pobuđuju jedne druge, kroz sinapse. Uloga praga osetljivosti bioloških neurona preslikava se iz tzv. aktivacijske funkcije (Hoskins i Himmelblau, 1988). Aktivacijska funkcija neurona prema tome predstavlja matematičku funkciju kojom neuron reaguje na prispelu informaciju, vrši izmenu ulaznog signala i taj signal predaje ostalim neuronima (Karray i de Silva, 2004).



Slika 4.1.2. Struktura veštačkog neurona (Dermuth i Beale, 2004)

Veštački neuron je prema tome jedinica izračunavanja koja dobija ulazne podatke, obrađuje ih i izlazne rezultate prosleđuje na dalju obradu. Matematički, model neurona prikazan na slici 4.2.1 može se predstaviti sledećim jednačinama:

$$z_j = \sum_{i=1}^n w_{ij} x_i \quad (4.1)$$

$$y_j = f(z_j + b_j) \quad (4.2)$$

Gde su: x_i – ulazni signali neurona, w_{ij} – težinski koeficijenti, z_j – linearni kombinator izlaza zavisen od ulaznog signala, $f(z_j)$ – aktivacijska funkcija, b_j – pomak (bias), y_j – izlazni signali neurona.

Tipična neuronska mreža može da se sastoji od nekoliko pa sve do više miliona jedinica (neurona) umreženih u serije slojeva. Slojevi u zavisnosti od uloge u neuronskoj mreži mogu biti ulazni (primaju podatke iz okoline), izlazni (daju rezultate obrade podataka) i

skriveni (nalaze se između ulaznog i izlaznog sloja). Svi slojevi su međusobno povezani, pri čemu su izlazi jednog sloja ulazi sledećeg. Ovo specifično uređenje povezivanja neurona u obliku mreže predstavlja arhitekturu tj. topologiju veštačke neuronske mreže (Al-Abri i Hilal, 2008). Prema tome, topologijom veštačke neuronske mreže se definiše broj slojeva, broj neurona u svakom sloju, aktivaciona funkcija prenosa i vrsta interkonekcija između neurona.

Tok informacija kroz neuronsku mrežu se odvija na dva načina u zavisnosti od toga kako su neuroni u mreži povezani. Kada šabloni informacija ulaze u mrežu putem ulaznog sloja koji dalje pobuđuje slojeve skrivenih jedinica, da bi na kraju završili u izlaznom sloju, pobuda se prenosi u jednom smeru od ulaza ka izlazu. Ove mreže nazivaju se nereketne odnosno tzv. „*feed-forward*“ mreže. To znači da svaka jedinica dobija svoj ulaz od jedinica iz prethodnog sloja, a zatim se ulazne vrednosti množe sa težinskim koeficijentima kroz koje su povezani. U svakoj jedinici ponderisani ulazi se sumiraju, određuje im se vrednost praga i podvrgavaju funkciji aktivacije koja se koristi kako bi se proizveo izlaz iz određene jedinice (Karray i de Silva, 2004). Ako je suma veća od određenog zadanog broja (prag osetljivosti), jedinica se aktivira i pobuđuje jedinice sa kojima je povezana (Milenković, 1997). Funkcija aktivacije može biti linearna ili nelinearna. Linearna aktivaciona funkcija predstavlja umnožak sumiranih ponderisanih vrednosti određenim faktorom, dok nelinearna aktivaciona funkcija može biti različitih oblika od kojih se najčešće koriste sigmoidalne, hiperbolične i harmoničke funkcije. Sa druge strane tok informacija kroz neuronsku mrežu može biti i sa povratnom spregom u ulazni sloj iz samog ulaznog, skrivenog ili izlaznog sloja, pa čak i sa skokovitim vezama, u kojima je jedan sloj povezan sa svim prethodnim. Ovakve mreže tzv. reketne („*feedback*“) pamte stanje u prethodnoj epohi, tako da sledeće stanje ne zavisi samo od ulaznih signala, već i od prethodnih stanja mreže (Milenković, 1997).

Analogno ljudskom neuronu veštačke neuronske mreže funkcionišu po principu učenja i detekcije zavisnosti između promenljivih koji im se predstave. (Hoskins i Himmelblau, 1988). Suština koncepta učenja neuronske mreže je učenje na primerima kako bi se izračunao izlaz mreže koji je najbliži realnim eksperimentalnim vrednostima. To je proces u kome se težinski koeficijenti i pragovi aktivacione funkcije postupno koriguju kroz iterativni postupak učenja zavisnosti između skupova ulazno-izlaznih podataka koji se odvija prema određenom algoritmu sve do trenutka kada je izlaz iz mreže, proveren na skupu podataka za testiranje zadovoljavajući (Jokić i sar., 2018). Provera izlaza iz mreže se vrši procenom odstupanja mreže od željenog odziva preko funkcije cilja, a u tu svrhu se koriste različiti izrazi poput ukupne kvadratne greške, srednje kvadratne greške, srednje apsolutne

greške ili neke druge funkcije koja u sebi nosi informaciju o grešci. Iterativni postupak podešavanja se ponavlja u određenom broju ciklusa (epoha) sve dok se greška ne smanji do zadovoljavajuće, ponekad unapred definisane vrednosti.

Kada se mreža istrenira sa dovoljnom količinom podataka ukoliko je procena odstupanja mreže od željenog odziva sa dozvoljenim pragom, potrebno je izvršiti validaciju performansi izabranog algoritma učenja, parametara učenja ili postavljene arhitekture neuronske mreže (Milenković, 1997). Validacija se vrši definisanjem mere tačnosti učenja, odnosno uspešnosti rešavanja postavljenog zadatka tako što se mreži dostavljaju drugačiji ulazni podaci za isti problem i posmatraju se izlazi, ali i performanse mreže (Sahoo i Ray, 2005).

Obučavanje neuronske mreže može da se sprovede na nekoliko načina: kao nadgledano obučavanje, nenadgledano obučavanje, a u literaturi se često navodi i podržano učenje. Kod nadgledanog obučavanja algoritam obučavanja ima pristup tačnim odgovorima za skup saopštenih ulaznih podataka odnosno, mreži se saopštavaju ulazni podaci i izlazi koji se žele dobiti za date ulazne podatke (Karray i de Silva, 2004). Dobijeni rezultati se porede sa očekivanim, pa s obzirom da su poznate ulazne vrednosti i željene izlazne vrednosti moguće je odrediti grešku tj. razliku između odziva mreže i željenog odziva. Korekcijom parametara mreže u narednim iteracijama smanjuje se razlika između željene i izračunate vrednosti odnosno vrši se konvergencija greške, čime se povećava uspešnost učenja (Curcio i Iorio, 2013). Karakterističan algoritam za nadgledano obučavanje je algoritam povratnog prostiranja (BP – „*back-propagation*“). Kod ovog algoritma prvo se koriguju težinski koeficijenti bliže izlaznom sloju, a zatim se korekcija kreće unazad sve do ulaznog sloja. Mreža uči redukujući razliku između stvarnih i željenih rezultata, sve dok se ove dve vrednosti ne poklope. Veoma važan korak kod algoritma nadgledanog obučavanja predstavlja izbor veličine koraka kojim se neuronska mreža približava optimalnom stanju tzv. stepen učenja. Vrednost je potrebno pažljivo odabrati jer preniski stepen rezultuje sporim učenjem, dok prevelike vrednosti mogu uzrokovati nestabilno učenje tj. učenje koje se ne može približiti ka rešenju sa najmanjom greškom (Dremuth i Beale, 2004). Učenje pomoću smanjivanja greške koje se zasniva na filtriranju optimalnih rezultata temelji se na tzv. Widrow-Hoff-ovom delta pravilu, a prema kojem je promena sinaptičke težine neurona proporcionalna proizvodu signala greške i ulaznog signala posmatrane sinapse (Milenković, 1997):

$$\Delta w_{ij} = \eta d_{Li} O_{Li} \quad (4.3)$$

Gde su: Δw_{ij} – vrednost za koju treba promeniti sinaptičku težinu w_{ij} u odnosu na zadati ulazno-izlazni par, η – stepen učenja, d_{Li} – greška na i-tom neuronu u sloju L za zadati ulazno-izlazni par, O_{Li} – vrednost dobijena primenom prenosne funkcije u L-tom sloju neurona.

Kod nenadgledanog učenja algoritam obučavanja (tzv. Kohonen-ov algoritam) ima pristup samo ulaznim podacima, a vrednosti izlaznih promenljivih iz skupa za učenje nisu poznate. Očekuje se da mreža sama otkriva statističke pravilnosti u strukturi ulaznih podataka i obučava se (Karray i de Silva, 2004). Ova vrsta učenja je samoorganizujućeg tipa zasnovana na kompetitivnom principu (Milenković, 1997). Prema ovom principu neuroni se takmiče za dozvolu da se aktiviraju za određeni skup ulaznih podataka. To podrazumeva da, kada jedan neuron jače reaguje na neki ulazni signal, on suprimira ili inhibira izlazne signale iz drugih neurona iz iste grupe (Curcio i Iorio, 2013). Neuronske mreže ovog tipa rade u dve faze: učenje i mapiranje. Mreža se sastoji iz samo dva sloja ulaznog i izlaznog koji su međusobno povezani. Neuroni u izlaznom sloju po prepoznavanju ulaznih podataka razvrstavaju neurone u klase u zavisnosti od toga koji su neuroni aktivni (Milenković, 1997). Polazeći od slučajno izabrane topološke mape učenjem se izgrađuje mapa koja održava prirodne veze između ulaznih podataka.

Primena neuronske mreže u određenoj situaciji značajno zavisi od sposobnosti generalizacije, kao i od kvaliteta ulaznih podataka i parametara procesa obuke. Sposobnost generalizacije predstavlja mogućnost neuronskih mreža da daju tačan odziv i za vrednosti ulaznih parametara koji nisu bili predstavljeni mreži tokom procesa učenja (Marković i sar., 2015). Suštinski, veštačke neuronske mreže su simulacije sposobne da modeluju veoma složene i nelinearne sisteme sa velikim brojem međusobno povezanih parametara. Ne zahtevaju detaljne informacije nego koriste raspoložive podatke i predviđaju odnose između ulaznih i izlaznih parametara.

Danas se u primeni veštačkih neuronskih mreža najčešće nalaze razne modifikacije nadgledanog obučavanja algoritmom povratnog prostiranja greške koji se međusobno razlikuju prema brzini konvergencije prilikom traženja rešenja. Oni uključuju klasične metode numeričkog rešavanja sistema nelinearnih jednačina kao što su gradijentne metode ili

Jakobijan grešku pri čemu uzimaju u obzir težinske koeficijente (Karray i de Silva, 2004). To su kvazi Newtonova metoda, metoda Bayes-ove regularizacije, metoda skaliranog konjugovanog gradijenta, Polak-Ribiere konjugovani gradijent i dr. Međutim najbrži algoritam je Levenberg–Marquardt algoritam.

4.1 Veštačke neuronske mreže u modelovanju mikrofiltracije

Pošto mikrofiltracija zavisi od velikog broja procesnih parametara (protok suspenzije, transmembranski pritisak, koncentracija napojne smeše, distribucija veličine čestica, itd.) projektovanje ove tehnološke operacije zahteva detaljno poznavanje njenih karakteristika prvenstveno fenomena u blizini površine i u samoj membrani koji izazivaju smanjenje fluksa permeata tokom vremena. Kako nije u potpunosti uspostavljena korelacija između različitih fizičkih, bioloških i hemijskih faktora koji utiču na smanjenje fluksa permeata tokom vremena jasno je da bi u cilju dobijanja relevantnih podataka bilo potrebno izvršiti brojne eksperimente, što iziskuje izuzetno mnogo vremena i resursa. Kompleksnost ovog zadatka dovela je do upotrebe veštačkih neuronskih mreža za modelovanje i simulaciju mikrofiltracije kao korisnog tehničkog alata za rešavanje složenih nelinearnih sistema sa velikim brojem međusobno povezanih parametara koji se ne mogu jednostavno prikazati u formi jednačine (Da Silva i sar., 2008, Avarzaman i sar., 2017).

Jedna od prvih istraživanja primene koncepta neuronskih mreža za modelovanje mikrofiltracije sežu još 1995. kada su Dornier i sar. (1995) izgradili dinamički model neuronske mreže prljanja membrane tokom unaksne mikrofiltracije suspenzije gustog soka šećerne trske. Model je zasnovan na pravilu povratnog rasprostiranja greške sa ukupno 8 neurona u dva skrivena sloja i sigmoidalnom aktivacionom funkcijom za predviđanje hidrodinamičkog otpora membrane pri konstantnom i promenljivom transmembranskom pritisku i protoku napojne smeše. Rezultati su pokazali konvergenciju od 97% sa eksperimentalnim podacima koja je ukazala da model neuronske mreže može sa visokom tačnošću predvideti hidrodinamički otpor membrane. Na sličan način su Hamachi i saradnici (1999) koristili model neuronske mreže za ispitivanje uticaja različitih operativnih uslova na fluks permeata i debljinu formirane pogače tokom unakrsne mikrofiltracije bentonitne suspenzije različitih koncentracija. Autori su zaključili da bi primena modela neuronskih mreža za procenu debljine pogače predstavljala značajan doprinos praćenju radnih uslova mikrofiltracije pogotovo potrebe zaustavljanja procesa i pokretanja postupka čišćenja ili

potpune regeneracije membrane. Vodeći se ovim zaključcima Madeani i sar. (2012) primenili su model veštačke neuronske mreže sa fuzi logikom za predviđanje operativnih performansi tokom postupka hemijskog čišćenja membrane. Razmatran je uticaj različitih koncentracija natrijum hidroksida i natrijum dodecil sulfata na regeneraciju fluksa i uklanjanje hidrauličnog otpora. Upotrebljen je algoritam sa propagacijom greške unazad, a optimalna struktura mreže (ona koja daje minimalnu srednju kvadratnu grešku) uspostavljena je sa 5 neurona u ulaznom sloju (tip sredstva za čišćenje, koncentracija sredstva za čišćenje, temperatura, vreme unakrsne mikrofiltracije i brzina proticanja sirovog mleka), dva skrivena sloja sa 4 i 9 neurona po sloju i logaritamskom sigmoidalnom aktivacionom funkcijom. Adekvatno fitovanje eksperimentalnih rezultata u odnosu na predviđene vrednosti utvrđeno je na osnovu relativno visoke vrednosti koeficijenta determinacije od oko 99%.

Chellam (2005) je objavio rezultate predviđanja specifičnog fluksa neuronskim mrežama za mikrofiltraciju nekoliko različitih suspenzija pod širokim rasponom hidrodinamičkih parametara (inicijalni transmembranski pritisak, vreme filtracije, početni fluks, brzina smicanja) i pri raznim koncentracijama napojne smeše. Utvrđeno je da je samo jedan skriveni sloj bio dovoljan, dok se sa povećanjem broja skrivenih neurona greška u početku smanjila, a kasnije je porasla verovatno zbog prekomernog treniranja. Za određivanje relativnog uticaja pojedinih ulaznih promenljivih na izlazne vrednosti autor je upotrebio Garson-ovu metodu. Ova metoda uključuje razdvajanje apsolutnih vrednosti sinaptičkih težina svakog skrivenog neurona u komponente povezane sa svakim ulazom u neuronsku mrežu. Veće vrednosti ukazuju na veći relativni uticaj pojedinih ulaznih parametara na izračunavanje izlaznih promenljivih. Primenom navedene metode inicijalni fluks permeata je najvažniji operativni parametar koji utiče na prljanje membrane tokom mikrofiltracije polidisperznih suspenzija. Sa druge strane, utvrđeno je da brzina smicanja neznatno utiče na specifični fluks tokom unakrsne filtracije monodisperznih suspenzija. Međutim, primenom Garson-ove metode autor je zanemario kako pozitivne tako i negativne uticaje pojedinih ulaznih promenljivih, što može navesti na pogrešno tumačenje njihovog uticaja (Olden i Jackson, 2002, Olden i sar., 2004).

Pri izboru arhitekture neuronske mreže veoma je važno odrediti adekvatan broj neurona u skrivenom sloju. Veći broj neurona u skrivenom sloju dovodi do boljih mogućnosti predviđanja nelinearnih promena tokom mikrofiltracije naročito ukoliko se uzme u obzir raspodela veličine čestica u napojnoj suspenziji (Chellam, 2005). Međutim, suviše veliki broj neurona dovodi do formiranja mreže sa prevelikim brojem parametara, te je mreža sklona

pretreniranju čime se pogoršava njena sposobnost da uči. Sa druge strane, simulacijom mikrofiltracije suspenzije fosfata i letećeg pepela kombinacijom različitih neuronskih mreža Aydiner i sar. (2005) zaključuju da mreža s premalim brojem neurona, neće biti u stanju aproksimirati zadane nelinearne odnose na ispravan način. Takođe, autori tvrde da nema generalnog pravila za utvrđivanje optimalnog broja neurona u skrivenom sloju koji omogućava mreži da ispravno modeluje odnose između ulaznih i izlaznih podataka te je potrebno osloniti se na metodu probe i greške. Do istih zaključaka su došli i Fu i sar. (2005) predviđanjem adsorpcije proteina goveđeg seruma unutar polietilenske membrane veštačkom neuronskom mrežom sa 5 neurona u jednom skrivenom sloju i sigmoidalnom aktivacionom funkcijom. Rezultati su pokazali bolje fitovanje podataka dobijenih neuronskom mrežom sa eksperimentalnim vrednostima nego onih koji su izračunati konvencionalnom difuzionom jednačinom baziranom na Fik-ovom drugom zakonu. Autori zaključuju da neuronske mreže mogu na zadovoljavajući način predvideti veoma složene interakcije između seruma proteina i sintetičkih membrana jer ne zavise od detaljnog poznavanja tog kompleksnog mehanizma (Fu i sar., 2005).

Na osnovu eksperimentalnih rezultata koja su dobili Faibish i sar. (1998) ispitujući pad fluksa permeata tokom unakrsne mikrofiltracije koloidinih suspenzija, Chen i Kim su 2006. ustanovili da neuronska mreža sa radijalnom baznom funkcijom (RBN) ima bolju predvidljivost od neuronske mreže sa propagacijom greške unazad. Autori su utvrdili da RBN brže konvergira ka optimalnom rešenju, ali je osetljivija na dimenzionalnost problema (tj. na broj ulaznih promenljivih). S druge strane bez obzira na dostupnost ili gustinu podataka o treningu, predviđanje propagacijom greške unazad može dovesti do velikih ekstrapolacijskih grešaka. Međutim, Sahoo i Rai (2006) ističu da je pri ovom istraživanju korišćena određena mrežna arhitektura bez optimizacije i u skladu sa tim predložili su upotrebu genetskog algoritma za utvrđivanje optimalne geometrije mreže kao alternativu metode probe i greške. S druge strane, Cheng i sar. (2008) ističu da se genetskim algoritmom optimalan broj neurona određuje slučajnim odabirom što može dovesti do prekomernog treniranja ukoliko je broj neurona prevelik i da oba tipa neuronske mreže imaju svoje prednosti i mane. S toga su predložili modelovanje prljanja membrane tokom unakrsne mikrofiltracije koloidnih suspenzija modifikovanom neuronskom mrežom koja uključuje oba tipa neuronskih mreža. Autori su za iste eksperimentalne podatke treniranje mreže sproveli u tri koraka uključujući izbor kandidata neurona za početnu strukturu neuronske mreže na osnovu metode binarne particije da bi se otkrile lokacije ulaznih neurona koji imaju minimalnu potrebnu gustinu

distribucije, uklanjanje suvišnih neurona koji nemaju značajan doprinos željenim vrednostima permeatnog toka primenom Gram–Schmidt-ovog algoritma i rafiniranje inicijalne neuronske mreže metodom gradijentnog pretraživanja. Optimalna arhitektura je utvrđena sa 5 ulaznih neurona (jonska snaga, pH vrednost, transmembranski pritisak, veličina čestica, vreme filtracije), 4 skrivena sloja sa 15 neurona od kojih su 5 neurona sa linearnom aktivacionom funkcijom dok su ostalih 10 sa radijalnom aktivacionom funkcijom i jednim izlaznim neuronom. Nedostatak ovog pristupa je u tome što primena metode gradijentnog pretraživanja može dovesti do problema dimenzionisanja ulaznih neurona, jer veća gustina distribucije ulaznih neurona eksponencijalno dovodi do povećanja domena uniformno određenih particija (Wei i sar., 2009). Neuronsku mrežu sa radijalnom baznom funkcijom upotrebili su i Ghandehari i sar. (2013) za predviđanje fluksa permeata i faktora retencije tokom unakrsne mikrofiltracije proteina kroz hidrofилnu polietersulfonsku membranu. Odabrane ulazne promenljive su transmembranski pritisak, protok napojne smeše (jer je ovaj parametar u direktnoj vezi sa naponom smicanja na površini membrane čija promena direktno utiče na faktor retencije i koncentracionu polarizaciju), koncentracija proteina, temperatura i pH vrednost napojne suspenzije. Autori su poredili performanse neuronske mreže sa radijalnom funkcijom sa 300 neurona u skrivenom sloju i neuronske mreže sa povratnim prostiranjem greške sa dva skrivena sloja optimalne arhitekture 5:6:8:1 za predviđanje fluksa i 4:5:6:1 za predviđanje faktora retencije. 60% od ukupnog broja eksperimentalnih podataka iskorišćeno je za trening, 20% za validaciju i preostalih 20% za testiranje mreže. Rezultati su pokazali konvergenciju od oko 98% za neuronsku mrežu sa povratnim prostiranjem greške i 99% za neuronsku mrežu sa radijalnom funkcijom. Međutim, može se zaključiti da iako neuronska mreža sa radijalnom funkcijom pruža bolje performanse u poređenju sa mrežom sa povratnim prostiranjem greške sigurno će pružiti sporiji odgovor zbog velikog broja neurona u skrivenom sloju.

Razvojem modela neuronskih mreža procesa mikrofiltracije suspenzija kvasca bavili su se Ni Mhurchu i sar., (2006) i Hillal, (2012). U prvom istraživanju autor je ispitivao pad fluksa permeata i specifični otpor prljanja membrane tokom statičke mikrofiltracije. Autori navode da specifični otpor linearno raste sa pritiskom i ističu kompleksnu zavisnost pH i jonske snage. Optimalnu topologiju mreže čini 5 neurona u ulaznom sloju (pH vrednost, koncentracija ćelija kvasca, koncentracija soli, veličina pora, pad pritiska), jedan skriveni sloj sa 9 neurona koji koriste funkciju sigmoidalne aktivacije i jedan neuron u izlaznom sloju (specifični otpor i fluks permeata redom). Rezultati predviđanja su pokazali prosečnu grešku

manju od 10% između eksperimentalno utvrđenih i predviđenih podataka. Doprinos ovog istraživanja autor ističe u lakoj primenljivosti modela na unakrsnu mikrofiltraciju. Doduše, u model je potrebno uključiti dodatne ulazne promenljive kao što su brzina unaksnog proticanja i geometrija filtracionog modula zbog teškoća eksperimentalnih merenja specifičnog otpora. U drugom istraživanju autor primenjuje model neuronske mreže na predviđanje fluksa permeata tokom unakrsne mikrofiltracije sa promotorom turbulencije. Ulazne promenljive su početni pritisak, temperatura, koncentracija napojne smeše i brzina unaksnog proticanja. Kao i u prethodnom istraživanju upotrebljena je neuronska mreža sa propagacijom greške unazad i funkcija sigmoidalne aktivacije neurona. Rezultati su pokazali konvergenciju od oko 94% za pritisak i ulaznu temperaturu, dok je za koncentraciju napojne smeše stepen konvergencije iznosio 98%. Rad je pokazao kako se veštačka neuronska mreža može koristiti za dinamičko predviđanje stepena prljanja membrane, taloženja čestica u cilju poboljšanja održivosti fluksa i efikasnosti membrane kao funkcije pritiska, temperature i brzine protoka.

U daljim istraživanjima predviđanja parametara mikrofiltracije različitih suspenzija korišćene su neuronske mreže obučavane algoritmom sa propagacijom greške unazad, a zbog stepena konvergencije i performansi mreže u pronalaženju najboljeg rešenja upotrebljen je „Levenberg-Marquardt“ metod treninga (Cheng i sar., 2008, Da Silva i sar., 2008, Hilal i sar., 2008, Liu i sar., 2009, Guardix i sr., 2010, Hwang i Choi., 2010a, Nanadi i sar., 2010, Soleimani i sar., 2013, Ni Mhurecu i sar., 2010). Osnovna razlika između ispitivanih neuronskih mreža ogleda se u aktivacionoj funkciji, broju skrivenih slojeva (najčešće samo jedan) i broju neurona u skrivenom sloju, koji se: pretpostavlja, dobija proračunom na osnovu broja neurona u ulaznom i izlaznom sloju ili broja neurona u ulaznom sloju i broja podataka za obučavanje mreže ili se određuje metodom probe i greške. Svi autori ističu neophodnost adekvatnog treniranja mreže i normalizacije ulaznih podataka.

„Levenberg-Marquardt“ algoritam treninga predstavlja poboljšanje metoda prostiranja greške unazad korišćenjem ranog zaustavnog kriterijuma za poboljšanje brzine obuke i efikasnosti neuronske mreže. Osnovni nedostatak „Levenberg-Marquardt“ algoritma za učenje je problem prekomernog treniranja tzv. „overfitting-a“ (Curcio i sar., 2006, Sahoo i sar., 2006). Naime, nakon obuke sistem postiže minimalnu vrednost greške na ulazno-izlaznom skupu podataka, ali kad se na ulaz mreže dovedu novi podaci na kojima mreža nije učila, ta greška je jako velika. Prema tome mreža nema dovoljno „znanja“ za generalizaciju ili aproksimaciju novih situacija. Za prevazilaženje ovog problema autori su predložili Bayes-ovu regularizaciju. Ovom tehnikom proširuje se tzv. funkcija uspešnosti za dva nova

parametra koji definišu prioritet postupka podešavanja težinskih koeficijenata (Demuth i Beale, 2004). Na ovaj način algoritam ne minimizira samo grešku, nego traži i minimalni broj podesivih parametara mreže potrebnih za ostvarenje minimalne greške. S obzirom da algoritam minimizira i broj težinskih koeficijenata koji će se podešavati, može se koristiti i kao pomoć u određivanju optimalnog broja neurona skrivenog sloja. Primenom ovog algoritma pored male srednje kvadratne greške u treningu mreže postiže se i najmanja vrednost težinskih koeficijenata, pa se očekuje da ovakva mreža ima odličnu sposobnost generalizacije (Madaeni i sar., 2012, Nourbakhsh i sar., 2014). Model veštačke neuronske mreže sa trening algoritmom Bayes-ove regularizacije uspešno je razvijen za modelovanje fluksa unakrsne mikrofiltracije otpadnih voda industrije skroba sa i bez prisustva statičkog promotora turbulencije (Jokić i sar., 2018). Za ulazne promenljive odabrani su protok napojne smeše, transmembranski pritisak, vreme sedimentacije otpadnih voda i vreme mikrofiltracije. Optimalna arhitektura veštačke neuronske mreže utvrđena je kao 4-10-1 sa hiperbolično tangentnom sigmoidalnom aktivacionom funkcijom. Analiza apsolutne relativne greške pokazala je zadovoljavajuće prognoze permeatnog fluksa za više od 90% podataka. Kod mikrofiltracije bez statičkog promotora turbulencije samo 2% podataka imala su apsolutnu relativnu grešku veću od 20%, dok je za mikrofiltraciju sa statičkim promotorom turbulencije taj broj podataka iznosio 1%. Na kvalitet rezultata osim izbora promenljivih znatno utiče i način sprovođenja učenja i validacije, odnosno ispravna podela ukupnog uzorka na poduzorke za treniranje, validaciju i testiranje mreže. Zato je 80% eksperimentalno dobijenih podataka upotrebljeno za određivanje težinskih koeficijenata i afiniteta mreže, 10% podataka iskorišćeno je za validaciju performansi izabranog algoritma učenja i odlučivanje o zaustavljanju obuke, a 10% za verifikaciju sposobnosti kriterijuma zaustavljanja i procenu rada neuronske mreže na novom setu podataka. Autori su utvrdili da vreme filtracije i brzina protoka napojne smeše imaju najveći uticaj na dinamički fluks permeata u oba načina mikrofiltracije, a da se uticaj brzine protoka povećava za oko 30% kada se statički turbulentni promotor postavi u membranski kanal.

Liu i sar. (2014) razvijaju model neuronske mreže za određivanje efikasnosti poboljšanja fluksa promotorom turbulencije tokom unakrsne mikrofiltracije suspenzije kalcijum karbonata koristeći brzinu proticanja, transmembranski pritisak i koncentraciju napojne suspenzije kao ulazne promenljive. Model nerekuretna tzv. „*feedforward*“ mreže treniran je povratnim prostiranjem greške unazad i optimizovan genetskim algoritmom. Rezultati studije sugerišu da je model neuronske mreže sa jednim skrivenim slojem dovoljan

da tačno predstavi eksperimentalne podatke, a optimalan broj neurona u skrivenom sloju ograničen je na 12 kako bi se izbeglo prekomerno treniranje. Na osnovu analize krive sume srednje kvadratne greške tokom treninga mreže u odnosu na broj epoha utvrđeno je da logaritamska sigmoidalna aktivaciona funkcija daje najbolje vrednosti. Procenjen koeficijent poboljšanja efikasnosti fluksa permeata povećava se porastom koncentracije napojne suspenzije, a sa povećanjem transmembranskog pritiska ili ulazne brzine proticanja u početku procesa raste, a zatim opada (Liu i sar., 2014). Prema autorima transmembranski pritisak ima najveći uticaj na koeficijent efikasnosti poboljšanja fluksa permeata. Koeficijent determinacije između predviđene i eksperimentalno utvrđene vrednosti koeficijenta poboljšanja fluksa permeata iznosio je 98,9%.

Iste godine Nourbakish i sar., predlažu model za predviđanje fluks permeata tokom unakrsne mikrofiltracije soka crvene šljive koji se sastoji iz mreže sa jednim skrivenim slojem topologije 5-22-1. Kao ulazni podaci korišćeni su transmembranski pritisak, temperatura, protok, veličina pora i vreme trajanja filtracije. Mreža je trenirana modelom prostiranja greške unazad sa gradijentnom aktivacionom funkcijom i optimizovana postupkom odzivne površine. Rezultati su pokazali veoma dobro predviđanje fluksa permeata s obzirom da je vrednosti koeficijenta determinacije iznosila 96%.

Novija istraživanja simulacije mikrofiltracije neuronskim mrežama sprovedena su za bistrenje suspenzije soka šećerne repe (Shahriari i sar., 2017). Autori su upotreбили Levenbergov model obučavanja neuronske mreže i varirali različite arhitekture mreže u pronalaženju najboljeg rešenja koji će dati maksimalni koeficijent determinacije eksperimentalnih podataka za turbiditet, mutnoću soka šećerne repe i koeficijent retencije. Neuronska mreža sa tangentnom prenosnom funkcijom i 8 neurona u jednom skrivenom sloju rezultovala je maksimalnom vrednošću koeficijenta korelacije turbiditeta soka šećerne repe u zavisnosti od temperature i vremena od 0,987. Neuronska mreža sa 4 neurona u jednom skrivenom sloju i sigmoidalnom prenosnom funkcijom rezultovala je maksimalnim stepenom korelacije od 0,98 za mutnoću soka šećerne repe i minimalnom greškom, a neuronska mreža sa 2 neurona u jednom skrivenom sloju rezultovala je minimalnom greškom i maksimalnim stepenom korelacije od 0.981 za koeficijent retencije. Takođe, sprovedeno modelovanje neuronske mreže različitim procentima podataka za obuku dalo je najbolje rezultate kada je upotrebljeno 60% podataka za trening mreže, 35% za validaciju i 5% za testiranje.

Za modelovanje mikrofiltracije uglavnom su korišćene neuronske mreže sa radialnom baznom funkcijom ili neuronske mreže obučavane algortimom sa propagacijom

greške unazad koja koristi tangencijlanu, sigmoidalnu ili pak logističku aktivacionu funkciju. Istraživanja su uglavnom usmerena na procenu pada fluksa permeata kao funkciju hidrodinamičkih parametara (transmembranski pritisak, protok suspenzije, brzina smicanja), karakteristika napojne smeše (sastav, pH vrednost) i vremena. Veštačke neuronske mreže ne zahtevaju detaljno poznavanje sistema, nego koriste raspoložive eksperimentalne podatke i predviđaju odnose između ulaznih i izlaznih parametara što je od izuzetne važnosti naročito u slučajevima kada nije određena ili nije dobro formulisana njihova funkcionalna zavisnost (Al Abri i sar., 2008).

EKSPERIMENTALNI DEO I REZULTATI

5. Materijal i metod

Primena koncepta neuronskih mreža za predviđanje fluksa permeata u okviru istraživanja obuhvaćenih ovom doktorskom disertacijom podrazumevala je obradu eksperimentalnih rezultata mikrofiltracije kultivacionih tečnosti dobijenih tokom proizvodnje biološki aktivnih komponenti koje se koriste u biološkoj kontroli poljoprivredne proizvodnje i proizvodnji drugih bioaktivnih jedinjenja za npr. prehrambenu i farmaceutsku industriju. Mikroorganizmi korišćeni za kultivaciju su *Streptomyces hygroscopicus* i *Bacillus velezensis*. Vrsta *Bacillus velezensis* je gram-pozitivna bakterija čije su ćelije štapićastog oblika, širine 0,5 μm i dužine 1,5-3,5 μm (Mota i sar., 2002). *Bacillus velezensis* su uglavnom zastupljene u komercijalnim proizvodima mikrobioloških đubriva i biokontrolnih agenasa za suzbijanje aktivnosti i smanjenje populacije fungálnih i bakterijskih fitopatogena. *Streptomyces hygroscopicus* je rod gram-pozitivnih bakterija koja raste u raznim sredinama, a po svom obliku podseća na vlaknaste gljive. Vrste *Streptomyces* izvor su hiljade bioaktivnih jedinjenja koja se koriste u biološkoj kontroli, farmaciji i prehrambenoj industriji (Hossain i Rahman, 2014, Salas-Leyva i sar., 2017, Marzban i sar., 2016). Ispitivanje mogućnosti modelovanja mikrofiltracije kultivacionih tečnosti vršeno je za različite uslove sprovođenja postupka mikrofiltracije: u uslovima postupka ugušćivanja (koncentrisanja), u uslovima recirkulacije napojne suspenzije, u uslovima primene dvofaznog toka uduvavanjem vazduha u tok napojne smeše, kombinovanog postupka primene promotora turbulencije i dvofaznog toka i u stacionarnim uslovima.

5.1 Eksperimentalni plan i metod

Podaci za razvoj modela predviđanja fluksa permeata zasnovanog na konceptu veštačkih neuronskih mreža prikupljeni su iz realizovanih eksperimenata mikrofiltracije kultivacionih tečnosti dobijenih tokom uzgajanja biomase mikroorganizama *Streptomyces hygroscopicus* i *Bacillus velezensis*, na aparaturi razvijenoj u prethodnim istraživanjima. Eksperimenti mikrofiltracije izvedeni su upotrebom monotubularne keramičke membrane proizvođača „Tami“ (Nemačka) prečnika pora od 200 nm (koji omogućava potpuno

razdvajanje mikrobne mase), dužine 250 mm i aktivne površine od 0,0043 m², a kao promotor turbulencije upotrebljen je statički mikser tipa Kenics izrađen od nerđajućeg čelika prečnika 6 mm i dužine 230 mm (što odgovara aktivnoj dužini membrane). Primena modela neuronske mreže ispitivana su za svaki od setova eksperimentalnih podataka mikrofiltracije: bez primene postupaka za poboljšanje fluksa, sa primenom promotora turbulencije, sa primenom dvofaznog toka, za kombinovani postupak ove dve metode i u stacionarnim uslovima. Ukupni eksperimentalni rezultati iskorišćeni su za ispitivanje koncepta neuronskih mreža za modelovanje objedinjenih podataka mikrofiltracije sa primenom svih metoda poboljšanja fluksa permeata i modelovanje u stacionarnim uslovima.

Ispitivanja primene neuronskih mreža za modelovanje unakrsne mikrofiltracije tokom ugušćivanja izvršena su na eksperimentalnim podacima mikrofiltracije kultivacione tečnosti *Streptomyces hygroscopicus*. Kultivaciona tečnost dobijena je kultivacijom proizvodnog mikroorganizma *Streptomyces hygroscopicus* u Voulff-ovim bocama kapaciteta 2 L sa 500 mL kultivacionog medijuma. Sredstvo za uzgoj zasejano je sa 10% inokuluma, a bioproces je trajao 10 dana na 27 C mešanjem na rotirajućoj mikrobiološkoj tresilici uz spontanu aeraciju. Tokom unakrsne mikrofiltracije permeat nije recirkulisan u sud sa suspenzijom nego je konstantno odvođen iz sistema kako bi se dostigao željeni stepen ugušćivanja (VCR – „*volume concentration ratio*“) koji je postavljen na 2 (pošto je pri vrednostima većim od 2 fluks permeata praktično konstantan). VCR je faktor zapreminskog koncentrisanja, koji služi za izražavanje koncentracije retentata.

$$VCR = \frac{V_0}{V_0 - V_P} \quad (5.1.)$$

Gde su: V_0 – zapremina napojne smeše (m³) i V_P – zapremina permeata (m³)

Ispitivanja primene neuronskih mreža za modelovanje unakrsne mikrofiltracije u uslovima recirkulacije napojne suspenzije, u uslovima dvofaznog toka i kombinovane primene dvofaznog toka i promotora turbulencije, za objedinjene podatke primene svih metoda poboljšanja fluksa permeata i modelovanje u stacionarnim uslovima izvršena su na eksperimentalnim podacima mikrofiltracije kultivacione tečnosti *Bacillus velezensis*. Kultivaciona tečnost dobijena je kultivacijom proizvodnog mikroorganizma *Bacillus velezensis* u Voulff-ovim bocama kapaciteta 2 L sa hranljivom podlogom optimizovanog sastava na bazi komercijalnog glicerola koja je zauzimala 2/3 ukupne zapremine Vulfove

boce (Pajčin, 2019). Sredstvo za uzgoj zasejano je sa 10% inokuluma, a bioproces je trajao 96 sati na 28°C mešanjem na laboratorijskoj tresilici uz spontanu aeraciju (Pajčin, 2019). Tokom unakrsne mikrofiltracije retentat je recirkulisan u sud sa suspenzijom, a nakon merenja protoka i permeata kako bi se obezbedio konstantan sastav napojne smeše. Svi eksperimenti mikrofiltracije su izvedeni na temperaturi 25°C. Određivanje vrednosti fluksa permeata tokom mikrofiltracije u uslovima recirkulacije napojne smeše vršeno je u uslovima sa i bez prisustva statičkog mešača tipa Kenics, u uslovima dvofaznog toka i kombinovane primene dvofaznog toka i promotora turbulencije. Za potrebe eksperimenta mikrofiltracije u uslovima dvofaznog toka i kombinovanog postupka primene dvofaznog toka protok vazduha je meren i regulisan pomoću elektronskog masenog merača i regulatora protoka.

Eksperimentalni podaci su pripremljeni uključujući proveru integriteta podataka, greške kao što su nepravilno uneti podaci, duplirani podaci ili nepotpuni podaci koji se moraju ispraviti ili izbaciti. Upotrebom Box-Behnken-ov eksperimentalnog plana isključuju se eksperimenti sprovedeni pod ekstremnim uslovima koji zbog toga mogu dovesti do nezadovoljavajućih rezultata, a variranjem procesnih parametara smanjuje se broj potrebnih eksperimenata za opis nelinearnih sistema (Jokić i sar., 2010, Pajčin, 2019, Ferreira i sar., 2007). Primenjenim eksperimentalnim planom (3^3 – tri faktora varirana na tri nivoa, uz tri ponavljanja u centralnoj tački) utvrđene su ulazne projektne promenljive i njihovi rasponi koji su poslužili za razvoj modela neuronske mreže:

- Ulazne projektne promenljive u uslovima ugušćivanja prikazane su u tabeli 5.1.1. Kao dodatna promenljiva određeno je vreme trajanja procesa. Model neuronske mreže mikrofiltracije kultivacione tečnosti *Streptomyces hygroscopicus* u uslovima ugušćivanja razvijen je na ukupnim eksperimentalnim podacima koji su podeljeni u dve grupe i to: ukupno 211 podataka za razvoj modela neuronske mreže uz prisustvo statičkog promotora turbulencije (SM) i ukupno 220 podataka za razvoj modela bez prisustva statičkog promotora turbulencije (NSM).
- Ulazne projektne promenljive u uslovima recirkulacije napojne smeše prikazane su u tabeli 5.1.2. Kao dodatna promenljiva određeno je vreme trajanja procesa. Model neuronske mreže mikrofiltracije kultivacione tečnosti *Bacillus velezensis* u uslovima recirkulacije napojne suspenzije razvijen je na ukupnim eksperimentalnim podacima koji su podeljeni u dve grupe i to: ukupno 238 podataka za razvoj modela neuronske

mreže uz prisustvo statičkog promotora turbulencije (SM) i ukupno 220 podataka za razvoj modela bez prisustva statičkog promotora turbulencije (NSM).

- Ulazne projektne promenljive u eksperimentima mikrofiltracije u uslovima dvofaznog toka prikazane su u tabeli 5.1.3, a u eksperimentima sa kombinovanom primenom dvofaznog toka i statičkog mešača prikazane su u tabeli 5.1.4. Kao dodatna promenljiva u oba seta eksperimenata određeno je vreme trajanja procesa. Svi eksperimenti mikrofiltracije su izvedeni na temperaturi 25°C. Model neuronske mreže mikrofiltracije kultivacione tečnosti *Bacillus velezensis* u uslovima dvofaznog toka razvijen je na ukupno 245 eksperimentalnih podataka, dok je model kombinovanog postupka primene promotora turbulencije i dvofaznog toka razvijen na ukupno 343 podataka.
- Za ulazne projektne promenljive modela neuronske mreže objedinjenih podataka mikrofiltracije kultivacione tečnosti *Bacillus velezensis* iskorišćeni su svi prethodni eksperimentalni podaci (tabele 5.1.2., 5.1.3. i 5.1.4.), dok je model razvijen na ukupno 1115 eksperimentalnih podataka.
- Za ulazne projektne promenljive modela neuronske mreže u stacionarnim uslovima mikrofiltracije kultivacione tečnosti *Bacillus velezensis* iskorišćeni su svi prethodni eksperimentalni uslovi, odnosno vrednosti stacionarnog fluksa za sve navedene eksperimente. Model neuronske mreže mikrofiltracije kultivacione tečnosti *Bacillus velezensis* u stacionarnim uslovima za procenu fluksa permeata u stacionarnom stanju i specifične potrošnje energije razvijen je na ukupno 48 eksperimentalnih podataka.

Tabela 5.1.1. Ulazne promenljive u modelu veštačke neuronske mreže u uslovima ugušćivanja

Promenljiva	Vrednosti
Transmembranski pritisak (bar)	0,3; 0,6; 0,9
Protok napojne suspenzije (Lh ⁻¹)	40; 100; 160
Temperatura (°C)	30; 40; 50

Tabela 5.1.2. Ulazne promenljive u modelu veštačke neuronske mreže u uslovima recirkulacije napojne suspenzije

Promenljiva	Vrednosti
Transmembranski pritisak (bar)	0,2; 0,6; 1
Protok napojne suspenzije (Lh ⁻¹)	60; 120; 180

Tabela 5.1.3. Ulazne promenljive u modelu veštačke neuronske mreže u uslovima dvofaznog toka

Promenljiva	Vrednosti
Transmembranski pritisak (bar)	0,2; 0,6; 1
Prividna brzina proticanja napojne suspenzije (ms ⁻¹)	0,43; 0,87; 1,30
Prividna brzina proticanja vazduha (ms ⁻¹)	0; 0,2; 0,4

Tabela 5.1.4. Ulazne promenljive u modelu veštačke neuronske mreže u uslovima kombinacije dvofaznog toka i promotora turbulencije

Promenljiva	Vrednosti
Transmembranski pritisak (bar)	0,2; 0,6; 1
Prividna brzina proticanja napojne suspenzije (ms ⁻¹)	0,53; 1,06; 1,59
Prividna brzina proticanja vazduha (ms ⁻¹)	0; 0,23; 0,46

Protok permeata tokom mikrofiltracije izražen je preko vremena potrebnog da se sakupi 10 ml permeata, dok je fluks permeata u stacionarnom stanju određen iz protoka permeata po jedinici površine membrane prema sledećoj jednačini:

$$J_p = \frac{Q_p}{A} \quad (5.2.)$$

Gde su: J_p – fluks permeata (Lm⁻²h⁻¹), Q_p – protok permeata (Lh⁻¹) i A – površina membrane (m²).

Podaci su obrađeni metodologijom programskog alata „*Neural Network Toolbox*“, softverskog paketa Matlab, koji nudi funkcije i aplikacije za modelovanje složenih nelinearnih sistema koji se ne mogu jednostavno prikazati u formi jednačine (Mirabgheri i sar., 2015). Programski alat pored korišćenja postojećih arhitektura i algoritama daje mogućnost formiranja novih, međutim u ovom radu su isključivo korišćene postojeće arhitekture i algoritmi pozivanjem odgovarajućih naredbi. Tokom obučavanja mreže programski paket na osnovu odabira početne vrednosti jačina veza sinapsi između neurona u iterativnom postupku primenom odgovarajućeg algoritma obučavanja pronalazi vrednosti izlaznih promenljivih (Miljković i Aleksandrić, 2018).

Pored prethodnih istraživanja u okviru ove doktorske disertacije ispitana je i mogućnost objedinjavanja eksperimentalnih rezultata u cilju dobijanja jedne jedinstvene neuronske

mreže za simulaciju svih metoda poboljšanja fluksa i mogućnost primene ovih modela za procenu efikasnosti poboljšanja fluksa u stacionarnim uslovima, uz proveru adekvatnosti modela za predviđanje efekta postupaka poboljšanja fluksa sa energetskeg stanovišta. Efikasnost povećanja fluksa primenjenim hidrodinamičkim metodama određena je preko stacionarnog fluksa mikrofiltracije u svim pomenutim eksperimentima, dok je energetska efikasnost mikrofiltracije utvrđena preko specifične potrošnje energije (E).

Ekonomska opravdanost upotrebe hidrodinamičkih metoda za poboljšanje fluksa permeata kvantifikuje se preko specifične potrošnje energije koja je definisana kao gubitak hidrauličke snage (proizvod primenjenog protoka i pada pritiska kroz membranu) po jedinici zapremine permeata:

$$E = \frac{P}{J_p A} = \frac{Q_l \Delta p}{J_p A} = \frac{Q_{g-l} \Delta p}{J_p A} \quad (5.3.)$$

Gde su: E – specifična potrošnja energije (kWhm^{-3}), P – gubitak hidrauličke snage (W), J_p – fluks permeata ($\text{Lm}^{-2}\text{h}^{-1}$), A – površina membrane (m^2), Q_l i Q_{g-l} – protok napojne smeše, odnosno dvofaznog toka (m^3h^{-1}) i Δp – pad pritiska kroz membranu (Pa).

5.2. Dizajn neuronske mreže i obrada podataka

Prilikom modelovanja neuronske mreže izbor arhitekture tj. određivanje obrasca veza između neurona i parametara treniranja je najvažniji kriterijum koji u velikom delu određuje kvalitet dobijenog modela. Specifikacija arhitekture neuronske mreže podrazumeva određivanje broja skrivenih slojeva, broja skrivenih neurona u svakom skrivenom sloju, izbor aktivacionih funkcija neurona u skrivenom i izlaznom sloju, algoritma obuke neurona i drugih faktora kao što su brzina učenja neuronske mreže, broj epoha, određivanje impulsnog faktora i početne raspodele težinskih koeficijenata. Određivanje broja skrivenih slojeva i broja neurona u skrivenim slojevima naročito su važna jer direktno utiču na performanse modela i njegovu sposobnost generalizacije.

Skriveni slojevi u neuronskoj mreži mapiraju složene relacije između ulaznih i izlaznih promenljivih odnosno ulaza i izlaza modela. Pregledom literature može se videti da se u najvećem broju istraživanja koriste najviše tri skrivena sloja, a kada je reč o primeni neuronskih mreža za modelovanje procesa mikrofiltracije, većina autora koristi samo jedan skriveni sloj. Međutim, do sada, još nije predložen uopšten metođ za određivanje broja

skrivenih slojeva. U razmatranju broja skrivenih slojeva pošlo se od stava da neuronsku mrežu sa više od dva skrivena sloja karakteriše visoka složenost i da dodavanjem slojeva njih ne odlikuju poboljšane performanse (Hwang i Choi, 2010a, Nanadi i sar., 2010, Soleimani i sar., 2013, Ni Mhurcu i sar., 2010). S toga su na izbor modela mreže presudno uticale detaljne analize literaturnih podataka iz oblasti istraživanja primene neuronskih mreža za modelovanje procesa mikrofiltracije u kojima je model višeslojnog perceptona potpuno povezane troslojne nerekurentne neuronske mreže (neuronska mreža sa jednim skrivenim slojem) najpopularniji i najčešće korišćeni model (Asghari i sar., 2020).

Pri određivanju broja neurona u skrivenom sloju potrebno je istaći da suviše mali broj neurona rezultuje velikom greškom nakon procesa treninga i pri generalizaciji novih podataka, dok suviše veliki broj neurona iako dovodi do poboljšanja sposobnosti aproksimacije neuronskih mreža može izazvati tzv. zasićenje koje će rezultovati povećanjem greške pri novoj generalizaciji (Nourbakish i sar., 2014, Baghert i sar., 2019). Način određivanja optimalnog algoritma treninga neuronske mreže se uglavnom temelji na eksperimentu nad samim modelom, odnosno metodu probe i greške (Winiczenko i sar., 2018). Na osnovu toga je postepeno povećavan broj neurona u skrivenom sloju počevši od minimalne strukture sa jednim neuronom i ispitivanjem postignutih rezultata. Tokom obuke neuronske mreže sinaptičke težine pojedinih neurona podešavane su u smeru minimizacije srednje kvadratne greške podataka za obuku uz istovremeni proračun srednje kvadratne greške i koeficijenta determinacije podataka za proveru. Broj neurona u skrivenom sloju je variran dok nije dobijeno najmanje srednje kvadratno odstupanje među obučanim podacima. Po pitanju gornje granice broja neurona u skrivenom sloju isti je podešen na 15 za sve ispitivane modele, a pošto je neuronska mreža u velikoj meri zavisna od vrednosti početne težine i da bi se postigli najbolji rezultati, neuronske mreže su pokrenule 30 puta.

Aktivaciona funkcija predstavlja matematičku funkciju kojom se formira izlaz iz neurona kao funkcija ulaznih signala. Znajući da su veze između faktora procesa i performansi procesa mikrofiltracije nelinearne i složene, kao i da mreže koje koriste nelinearne transfer funkcije brže i bolje uče nelinearne veze iz ulaznih podataka, za aktivacione funkcije u skrivenom sloju izabrane su dve sigmoidalne funkcije (logistička i hiperbolična tangensna), dok je u izlaznom sloju korišćena linearna aktivaciona funkcija (tabela 5.2.1).

Izbor parametara treniranja, brzine učenja neuronske mreže, impulsnog faktora (momentum), epoha, početne raspodele težinskih koeficijenata takođe utiču na izgradnju

modela za obučavanje neuronske mreže kako bi se obezbedilo određivanje optimalnih vrednosti težinskih koeficijenata i pragova. Ovi parametri uglavnom utiču na vreme trajanja obuke pa su izabrane uobičajene preporučene vrednosti (Torrecilla i sar, 2006). Broj epoha (iteracija) u procesu treniranja predstavlja broj predstavljanja podataka neuronskoj mreži, pa je za najbolje poklapanje proračunatih vrednosti sa eksperimentalnim podacima maksimalan broj iteracija postavljen na 1500, ciljane srednja kvadratna greška na 0, a vrednost minimalnog gradijenta na $1 \cdot 10^{-10}$.

Tabela 5.2.1. Aktivacione funkcije u neuronskoj mreži

Aktivaciona funkcija	Povezanost	Jednačina
Tansig	ulazni-skriveni sloj	$f(x) = \frac{2}{1 + e^{-2x}} - 1$
Logsig	ulazni-skriveni sloj	$f(x) = \frac{1}{1 + e^{-x}}$
Puerlin	skriveni-izlazni sloj	$f(x) = x$

Kao izlazna promenljiva za obučavanje neuronskih mreža korišćen je podatak o dinamičkoj promeni fluksa permeata, čije predviđanje omogućava kvantifikovanje i opisivanje procesa mikrofiltracije, kao i fluks u stacionarnom stanju i specifična potrošnja energije za procenu efikasnosti primenjene metode poboljšanja fluksa permeata.

Određivanje adekvatnih ulaznih promenljivih koje utiču fluks permeata je od ključnog značaja za uspešan razvoj modela. Naime, važno je da se neuronskoj mreži prikaže što više promenljivih koje imaju uticaj na odabranu izlaznu promenljivu, s obzirom da neuronska mreža ima sposobnost da uoči zakonitosti i veze između tih promenljivih (Milenković, 1997). Generalno, izbor broja neurona u ulaznom sloju definisan je brojem nezavisno promenljivih koji su varirani tokom eksperimentalnog postupka. Međutim, kako se modelu ne bi predstavio suviše veliki broj ulaznih promenljivih koji mogu negativno uticati na kompleksnost neuronske mreže smanjujući njenu efikasnost primenjen je Box-Behnken-ov eksperimentalni plan. Primenom ovog eksperimentalnog plana utvrđene su ulazne projektne promenljive i njihovi rasponi koji su prikazani u tabelama 5.1.1-5.1.4.

Da bi se izbegle velike razlike u specifičnim težinskim koeficijentima pojedinih ulaznih promenljivih i sprečila opasnost da te promenljive pokažu veći uticaj nego što ga imaju u realnosti neophodno je pre početka obuke neuronske mreže izvršiti pripremu podataka

dobijenih eksperimentima (Sarkar i sar., 2009, Nandi i sar., 2010, Khayet i sar., 2013). Priprema eksperimentalnih podataka izvršena je normalizacijom prema sledećoj jednačini (Corbaton-Baquena i sar., 2016):

$$J_{normal} = (1 - \Delta^L - \Delta^U) \frac{J_P - J_{min}}{J_{max} - J_{min}} + \Delta^L \quad (5.5.)$$

Gde su: J_{normal} , J_P – normalizovana vrednost fluksa permeata i izmerena vrednost fluksa permeata na datom vremenu, respektivno, J_{max} , J_{min} –, maksimalna i minimalna vrednost fluksa permeata u seriji eksperimentalnih podataka, respektivno, Δ^U i Δ^L – gornja i donja vrednosti granice normalizacije koje daju ograničenu ekstrapolacionu sposobnost mreže (sa vrednošću od 0,01 za svaku granicu).

Preporučljivo je da se pre postupka treniranja mreže eksperimentalni podaci podele u tri skupa: za treniranje, za validaciju i za testiranje kako bi se sprečilo prekomerno ili nedovoljno treniranje mreže i na adekvatan način odredio zaustavni kriterijum obučavanja (Torrecilla i sar., 2006, Winiczenko i sar., 2018). Kod većine istraživanja veštačkih neuronskih mreža izbor načina razmeštanja podataka u poduzorke vršen je slučajnom raspodelom prema proizvoljno utvrđenim procentima. S toga su eksperimentalne serije podataka nasumičnim odabirom (korišćenjem *randperm* algoritma) podeljene na skup podataka koji će biti korišćen za obučavanje mreže, skup podataka za validaciju modela i skup podataka za proveru razvijenog modela.

Svaka kreirana arhitektura neuronske mreže obučena je iterativnim postupkom na setu podataka za treniranje koji je obuhvatio 70% podataka kako bi se odredili težinski koeficijenti i koeficijenti praga (biasa). 15% ukupnih podataka iskorišćeno je za evaluaciju performansi neuronske mreže u postupku obučavanja, odnosno za procenu biasa i težinskih koeficijenata, kao i za odlučivanje kada da se prekine sa obučavanjem, a poslednjih 15% podataka za proveru sposobnosti kriterijuma zaustavljanja i za procenu očekivanog rada mreže na novim skupovima podataka (tabela 5.2.2).

Najvažnija mera performansi neuronske mreže je tačnost predikcije. Podudaranje eksperimentalnih podataka i podataka dobijenih pomoću obučene neuronske mreže procenjeno je linearnom regresionom analizom koja se kvantitativno izražava Pearson-ovim koeficijentom korelacije (Paunović i Omorjan, 2014).

Tabela 5.2.2. Distribucija podataka u modelu neuronske mreže

Mod	trening	validacija	testiranje	UKUPNO
u uslovima koncentrisanja				
NSM	154	33	33	220
SM	147	32	32	211
u uslovima recirkulacije napojne smeše				
NSM	154	33	33	220
SM	166	36	36	238
u uslovima dvofaznog toka				
	171	37	37	245
u uslovima kombinovane primene dvofaznog toka i statičkog mešača				
	241	51	51	343
sa objedinjenim podacima				
	781	167	167	1115
u stacionarnim uslovima				
	36	6	6	48

Pearson-ov koeficijent ukazuje na jačinu veze između linearne povezanosti dve promenljive uzimajući vrednosti iz opsega od -1 do +1. Idealni slučaj predstavlja koeficijent korelacije koji je blizu krajnje pozitivne, odnosno negativne vrednosti, s tim da ukoliko je koeficijent bliži krajnjoj negativnoj vrednosti linearna zavisnost između promenljivih ukazuje na opadanje vrednosti jedne kada se vrednost druge promenljive povećava. Može se reći da model neuronske mreže pokazuje dobru korelaciju ukoliko je apsolutna vrednost Pearson-ovog koeficijenta izračunata preko sledeće jednačine $|r| \geq 0,8$:

$$r = \frac{\sum_{i=1}^n J_{\text{exp},i} J_{\text{pred},i} - n \overline{J_{\text{exp}}} \overline{J_{\text{pred}}}}{\sqrt{\sum_{i=1}^n J_{\text{exp},i}^2 - n \overline{J_{\text{exp}}}^2} \sqrt{\sum_{i=1}^n J_{\text{pred},i}^2 - n \overline{J_{\text{pred}}}^2}} \quad (5.6.)$$

Gde su: n – broj podataka, $J_{exp,i}$ i $J_{pred,i}$ – i -ta eksperimentalna vrednost fluksa permeata i vrednost predikcije fluksa permeata modela neuronske mreže, a $\overline{J_{exp}}$ i $\overline{J_{pred}}$ – aritmetičke sredine podataka za eksperimentalno utvrđenu i predviđenu vrednost fluksa permeata, respektivno.

Da bi se procenila mogućnosti primene veštačkih neuronskih mreža kao merilo tačnosti predikcije tj. reprodukovanja eksperimentalnih rezultata svaki izlazni skup predikcija modela neuronske mreže je upoređen sa odgovarajućom eksperimentalno određenom vrednošću koristeći koeficijent determinacije (R^2) i srednju kvadratnu grešku (MSE):

$$R^2 = 1 - \frac{\sum_{i=1}^n (J_{exp,i} - J_{pred,i})^2}{\sum_{i=1}^n (J_{exp,i} - J_{pred,avg})^2} \quad (5.7.)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (J_{exp,i} - J_{pred,i})^2 \quad (5.8.)$$

Gde su: n – broj podataka, a $J_{exp,i}$ i $J_{pred,i}$ – i -ta eksperimentalna vrednost fluksa permeata i vrednost predikcije fluksa permeata modela neuronske mreže.

Koeficijent determinacije (R^2) predstavlja kvadrat Pearson-ovog koeficijenta koji ukazuje na pouzdanost predviđanja jedne varijable pomoću druge, odnosno predstavlja procenat podataka najbliži liniji najboljeg fitovanja. Vrednosti koeficijenta determinacije kreću se od 0 do 1.

Rezimirajući prethodne korake u okviru istraživanja obuhvaćenih ovom doktorskom disertacijom za procenu fluksa permeata, odnosno specifične potrošnje energije, utvrđene ulazne promenljive su date tabelama 5.1.1-5.1.4., a kao dodatni parametar utvrđeno je vreme mikrofiltracije. Određivanjem funkcije cilja čije se vrednosti prate u procesu treniranja odabrani su koeficijent determinacije (R^2) i srednja kvadratna greška (MSE) kao indikatori nivoa generalizacije i parametara učinka obuke neuronske mreže, a koeficijent korelacije (r) je odabran kao dodatni parametar adekvatnosti fitovanja vrednosti eksperimentalno utvrđenog i neuronskom mrežom procenjenog fluksa permeata, odnosno specifične potrošnje energije. Kroz podešavanje težina veza između promenljivih u procesu učenja mreže pojedine

ulazne promenljive, kao i među promenljive u obliku skrivenih neurona imaju različiti značaj za model na osnovu toga kakav je njihov uticaj na izlaz mreže. Pripremom eksperimentalnih podataka normalizacijom uprošćen je prostor u kome neuronska mreža radi čima se ubrzava obučavanje mreže, ali se i omogućava bolja generalizacija. Pri tome je sprovedena i eliminacija određenih promenljivih kako bi se omogućilo neuronskoj mreži da otkrije skrivena nelinearna kretanja i kako bi se raspodela ulaznih promenljivih bolje uklopila u raspodelu predviđenih izlaza. Randomizacijom (ujednačavanjem) izvedeno je nasumično razvrstavanje eksperimentalnih podataka na grupu za obučavanje, grupu za validaciju i grupu za testiranje kako bi se izbalansirali efekti nekontrolisanih faktora na izlaznu promenljivu. Iako se postupkom pripreme originalnih podataka uklanja veći deo nestacionarnosti, određeni stepen još uvek ostaje kod nekih promenljivih. Nestacionarnost ima uticaj na efikasnost algoritama obuke i arhitekture neuronskih mreža pa je zbog toga neophodno testirati više algoritama kako bi se otkrili oni koji se mogu nositi s preostalom nestacionarnošću. Iz tog razloga u istraživanjima urađenih u okviru ove doktorske disertacije ispitivano je pet algoritama obuke neuronskih mreža.

Levenberg-Marquardt-ov algoritam obuke (*trainlm*) zasnovan je na poboljšanoj metodi obuke prostiranjem greške unazad korišćenjem ranog zaustavnog kriterijuma kako bi se postigla efikasnost i zadovoljavajuća brzina treninga neuronske mreže. Kod ovog algoritma korekcija težinskih koeficijenata se obavlja proporcionalno sa greškom, a teče od izlaznog ka ulaznom sloju. Težinski koeficijenti se u prvoj iteraciji pretpostavljaju, a zatim se u svakoj narednoj iteraciji modifikuju u pravcu smanjivanja greške dobijene prilikom poređenja izmerene i predviđene vrednosti. Obučavanje traje do dostizanja unapred određenog maksimalnog broja epoha ili do trenutka kada greška izlaza padne ispod prihvatljive granice. Obučavanje može biti i vremenski ograničeno u zavisnosti od veličine mreže, broja primera, zadanog limita epoha ili limita greške. Rano zaustavljanje je obezbeđeno ukoliko vremenom ne dolazi do poboljšanja validacije ili ako funkcija cilja ostane ista za unapred zadati broj epoha u nizu (npr. ako bi se u određenom broju iteracija dogodilo da srednja kvadratna greška modela počne da raste obučavanje se prekida). U većini objavljenih radova primene neuronskih mreža za modelovanje procesa mikrofiltracije zbog stepena konvergencije i performansi mreže u pronalaženju najboljeg rešenja upotrebljen je ovaj algoritam.

Bayes-ova regularizacija (*trainbr*) predstavlja modifikaciju Levenberg-Marquardt algoritma kojom se rešava problem smanjene sposobnosti generalizacije zbog "preobučavanja" modela (smanjena tačnost prilikom predstavljanja novog skupa podataka).

Iterativnim postupkom se osim minimiziranja greške postiže i minimalan broj podešivih parametara potrebnih za ostvarenje minimalne greške tako da se na ovaj način minimizira broj težinskih koeficijenata koji će se podešavati, a moguće je određivanje optimalnog broja neurona u skrivenom sloju. Kako se ovim algoritmom postiže mala vrednost srednje kvadratne greške i najmanja vrednost težinskih koeficijenata očekuje se da mreža ima odličnu sposobnost generalizacije. Radi upoređivanja, tačnost algoritma Bayes-ove regularizacije je otprilike pet puta veća od Levenberg-Marquardt-ove metode ranog zaustavljanja (Demuth i Beale, 1998).

Model rezilientnog povratnog prostiranja (*trainrp*) zasniva se na metodi konjugovanih gradijenata, a koristi se za rešavanje problema sporog dostizanja optimalnih vrednosti težinskih koeficijenata kod sigmoidalne aktivacione funkcije. Naime, za sigmoidalnu aktivacionu funkciju karakteristično je približavanje koeficijenta pravca (nagiba krive) nuli, što predstavlja problem koji uzrokuje veoma male promene u težinskim koeficijentima i koeficijentu praga iako su ove vrednosti daleko od optimalnih. Vrednost i predznak gradijenta greške određuje pravac i smer iterativne promene te se prema tome vrši korekcija težinskih koeficijenata i koeficijenata praga. Korekcija se vrši u smeru povećanja težinskih koeficijenata za veličinu koraka (faktor korekcije pravca) ako gradijent greške tokom dve sukcesivne iteracije ima isti predznak, odnosno smanjenja za veličinu koraka kada gradijent greške promeni predznak u odnosu na prethodnu iteraciju. Parametri treninga su prošireni za dve veličine: početnu veličinu koraka i maksimalnu veličinu koraka.

Model skaliranog konjugovanog gradijenta (*trainscg*) predstavlja kombinaciju Levenberg-Marquardt-ovog algoritma i principa konjugovanog gradijenta (koji se računa na osnovu vrednosti prethodnog gradijenta greške). Model obuke zahteva nešto veći broj iteracija, ali zato značajno smanjuje broj neophodnih računskih operacija, čime se dosta skraćuje trajanje obuke mreže, tako da model čini pogodnim za obuku neuronskih mreža sa velikim opsegom parametara. Zasniva se na principu spuštanja gradijenta greške koji se koristi za korekciju težinskih koeficijenata i koeficijenata praga ulaznih promenljivih.

Model jednostepenog sekantnog povratnog prostiranja greške unazad (*trainoss*) koristi linijsku funkciju pretraživanja za pronalaženje minimalne greške. Povratnim prostiranjem greške proračunava se pomeraj performansi u odnosu na težinske koeficijente i koeficijente praga, a zatim vrši se korekcija za pomeraj umožten faktorom koji će minimizovati preformanse duž pravca prostiranja. U svakoj narednoj iteraciji pravac prostiranja se izračunava preko novo proračunatog gradijenta i gradijenta iz prethodnog koraka.

6. Rezultati i diskusija

6.1. Modelovanje mikrofiltracije tokom ugušćivanja

Osnovni zadatak u postupku definisanja modela neuronske mreže predstavlja formiranje arhitekture neuronske mreže koja će biti korišćena, nakon čega će se vršiti određivanje optimalne strukture mreže i najboljeg algoritma za treniranje mreže, kao i funkcije cilja koja se minimizira za vreme treniranja (Mirbagheri i sar., 2015). Prema tome, za analizu odabran je model neuronske mreže sa 1 skrivenim slojem neurona pri čemu je svaki od neurona u ulaznom sloju povezan sa svakim od neurona u skrivenom sloju koji su opet povezani sa svakim od izlaznih neurona (potpuno povezana mreža). Ukupno je testirano 10 modela neuronskih mreža sa pet vrsta algoritama obuke (*trainlm*, *trainbr*, *trainrp*, *trainscg* i *trainoss*) i dva tipa prenosne funkcije (*tansig* i *logsig*) između ulaznog i skrivenog sloja (tabela 5.2.1) koji su varirani tokom treniranja neuronske mreže do pronalaženja optimalne arhitekture kojom se postižu najbolje predikcione performanse.

Broj neurona u ulaznom sloju određen je brojem nezavisno promenljivih koje su varirane tokom eksperimentalnog postupka, a koje su kao ključne promenljive koje utiču na pad fluksa permeata određene Box-Behnken-ovim eksperimentalnim planom (tabela 5.1.1) uz dodatan parametar, vreme trajanja mikrofiltracije. Broj neurona u izlaznom sloju određen je prema broju zavisnih promenljivih koje se aproksimiraju modelom neuronske mreže, odnosno fluks permeata je određen kao izlazna promenljiva. Kao aktivaciona, odnosno prenosna funkcija između skrivenog i izlaznog sloja odabrana je linearna aktivaciona funkcija (tabela 5.2.1). Pre obučavanja, eksperimentalni podaci su normalizovani primenom jednačine 5.5., a zatim su randomizacijom podeljeni u tri grupe: 70% za trening, 15% za verifikaciju i 15% za testiranje, kako je navedeno u poglavlju 5.2. (tabela 5.2.2). Maksimalni broj epoha je postavljen na 1500, minimalna srednja kvadratna greška na 0, a najmanji gradijent učinka na 10^{-10} . Broj neurona u skrivenom sloju postepeno je povećavan počevši od minimalne strukture sa jednim neuronom i ispitivanjem postignutih rezultata, minimalne srednje kvadratne greške i koeficijenta determinacije, za svaki od režima mikrofiltracije (rezultati za režim bez statičkog promotora turbulencije prikazani su u Prilogu 1, tabele P1.1 i P1.2, a za režim sa statičkim promotorom turbulencije u Prilogu 1, tabele P1.3 i P1.4.).

Na osnovu podataka za proveru u slučaju mikrofiltracije bez statičkog promotora turbulencije (NSM režim), kod svih prenosnih funkcija i algoritama treninga uočava se da mreža daje veću srednju kvadratnu grešku ako se za obuku koristi manji broj neurona u skrivenom sloju. Minimalne vrednosti srednje kvadratne greške pri Levenberg–Marquardt-ovom algoritmu treninga sa sigmoidalnom hiperboličnom prenosnom funkcijom (*trainlm tansig*) i sigmoidalnom logističkom prenosnom funkcijom (*trainlm logsig*), kao i pri treniranju mreže algoritmom koji koristi Bayes-ovu regularizaciju i sigmoidalnu hiperboličku prenosnu funkciju (*trainbr tansig*) od $1,48 \cdot 10^{-4}$ i $6,31 \cdot 10^{-5}$, $2,84 \cdot 10^{-4}$, respektivno, postignute su za 15 neurona u skrivenom sloju. Može se reći da povećanjem broja neurona u skrivenom sloju dolazi do pada srednje kvadratne greške (bliže postavljenoj ciljnoj vrednosti treninga) što ukazuje na dobru predikcionu sposobnost mreže. U slučaju korišćenja sigmoidalne logističke prenosne funkcije pri treniranju mreže algoritmom koji koristi Bayes-ovu regularizaciju (*trainbr logsig*) minimalna vrednost srednje kvadratne greške od $3,84 \cdot 10^{-4}$ postignuta je za 12 neurona u skrivenom sloju. Daljim povećanjem neurona dolazi do neznatnog rasta vrednosti srednje kvadratne greške mada je njena vrednost i dalje niža od postavljene ciljne vrednosti, pa se može reći da i ovaj model pokazuje relativno zadovoljavajuću predikcionu sposobnost. Pri korišćenju algoritma rezilientnog povratnog prostiranja i sigmoidalne hiperbolične prenosne funkcije (*trainrp tansig*) minimalna srednja kvadratna greška od $1,28 \cdot 10^{-2}$ postignuta je sa 8 neurona u skrivenom sloju, dok je pri istom algoritmu treniranja i korišćenju sigmoidalne logističke prenosne funkcije (*trainrp logsig*) minimalna srednja kvadratna greška od $1,48 \cdot 10^{-2}$ postignuta sa 6 neurona u skrivenom sloju. U slučaju korišćenja algoritma skaliranog konjugovanog gradijenta i sigmoidalne hiperbolične prenosne funkcije (*trainscg tansig*) minimalna srednja kvadratna greška od $1,07 \cdot 10^{-2}$ postignuta je sa 10 neurona u skrivenom sloju, dok je pri istom algoritmu u slučaju sigmoidalne logističke prenosne funkcije (*trainscg logsig*) minimalna srednja kvadratna greška od $1,41 \cdot 10^{-2}$ postignuta sa 5 neurona. Na kraju korišćenjem algoritma jednostepenog sekantnog povratnog prostiranja greške unazad i sigmoidalne hiperbolične funkcije (*trainoss tansig*) minimalna vrednost srednje kvadratne greške od $1,63 \cdot 10^{-2}$ postignuta je sa 3 neurona u skrivenom sloju, a u slučaju korišćenja sigmoidalne logističke funkcije (*trainoss logsig*) minimalna vrednost srednje kvadratne greške od $2,05 \cdot 10^{-2}$ postignuta je za 10 neurona u skrivenom sloju. Najlošije predikcione sposobnosti pokazuju modeli kod kojih je fluks permeata imao najveće vrednosti srednje kvadratne greške, odnosno najmanje vrednosti koeficijenta determinacije. Kao što se može videti iz prethodno navedenog najveće vrednosti

srednje kvadratne greške postignute su pri korišćenju algoritma rezilientnog povratnog prostiranja (*trainrp*), algoritma skaliranog konjugovanog gradijenta (*trainscg*) i algoritma jednostepenog sekantnog povratnog prostiranja greške unazad (*trainoss*). Red veličine srednje kvadratne greške ovih modela ne pada ispod $1 \cdot 10^{-2}$ što je prilično velika vrednost s obzirom da je red veličine srednje kvadratne greške kod Levenberg–Marquardt-ovog algoritma (*trainlm*) i algoritma sa Bayes-ovom regularizacijom (*trainbr*) oko $1 \cdot 10^{-4}$. Takođe, modeli sa algoritmom rezilientnog povratnog prostiranja (*trainrp*), algoritmom skaliranog konjugovanog gradijenta (*trainscg*) i algoritmom jednostepenog sekantnog povratnog prostiranja greške unazad (*trainoss*) postigli su manje vrednosti koeficijenta determinacije (manje od 0,85383). Na osnovu toga se može reći da u NSM režimu modeli rezilientnog povratnog prostiranja, skaliranog konjugovanog gradijenta i jednostepenog sekantnog povratnog prostiranja greške unazad ne postižu dobre predikcione sposobnosti.

Za skup podataka mikrofiltracije sa upotrebom statičkog promotora turbulencije (SM režim) minimalne vrednosti srednje kvadratne greške od $4,33 \cdot 10^{-5}$ i $5,25 \cdot 10^{-5}$ su postignute za 15 i 14 neurona u skrivenom sloju pri Levenberg–Marquardt-ovom algoritmu treninga sa sigmoidalnom hiperboličnom prenosnom funkcijom (*trainlm tansig*) i sigmoidalnom logističkom prenosnom funkcijom (*trainlm logsig*) pri istom algoritmu treninga, respektivno. Pri korišćenju algoritma koji koristi Bayes-ovu regularizaciju i sigmoidalnu hiperboličnu prenosnu funkciju (*trainbr tansig*) minimalna srednja kvadratna greška od $9,49 \cdot 10^{-5}$ je postignuta sa 13 neurona u skrivenom sloju, dok je u slučaju sigmoidalne logističke funkcije (*trainbr logsig*) minimalna vrednost srednje kvadratne greške od $5,68 \cdot 10^{-2}$ postignuta sa svega 2 neurona u skrivenom sloju. Za model neuronske mreže kod koje je korišćen algoritam rezilientnog povratnog prostiranja sa sigmoidalnom hiperboličnom prenosnom funkcijom (*trainrp tansig*) minimalna vrednost srednje kvadratne greške od $3,16 \times 10^{-3}$ postignuta je sa 10 neurona u skrivenom sloju, dok je za sigmoidalnu logističku prenosnu funkciju (*trainrp logsig*) minimalna srednja kvadratna greška od $8,75 \cdot 10^{-4}$ postignuta za 12 neurona u skrivenom sloju. Model neuronske mreže sa 6 neurona u skrivenom sloju pri korišćenju algoritma skaliranog konjugovanog gradijenta sa sigmoidalnom hiperboličnom prenosnom funkcijom (*trainscg tansig*) i istog algoritma sa sigmoidalnom logističkom funkcijom (*trainscg logsig*) dao je minimalnu srednju kvadratnu grešku od $1,82 \cdot 10^{-3}$ i $3,75 \cdot 10^{-3}$, respektivno. Korišćenjem algoritma jednostepenog sekantnog povratnog prostiranja greške unazad i sigmoidalne hiperbolične funkcije (*trainoss tansig*) minimalna vrednost srednje kvadratne greške od $4,53 \cdot 10^{-3}$ postignuta je sa 9 neurona u skrivenom sloju,

a u slučaju korišćenja sigmoidalne logističke funkcije (*trainoss logsig*) minimalna vrednost srednje kvadratne greške od $4,89 \cdot 10^{-2}$ postignuta je za 2 neurona u skrivenom sloju. Kao i u NSM režimu i ovde se uočava da povećanjem broja neurona u skrivenom sloju, pri korišćenju Levenberg–Marquardt-ovog algoritma za obe funkcije prenosa (*trainlm tansig*, *trainlm logsig*) i algoritma koji koristi Bayes-ovu regularizaciju sa sigmoidalnom logističkom funkcijom (*trainbr logsig*), vrednost srednje kvadratne greške više konvergira postavljenoj ciljnoj vrednosti u odnosu na ostale modele, što ukazuje na bolju moć predviđanja nelinearnih promena u posmatranom sistemu. Takođe, kod ovih modela koeficijent determinacije postiže veće vrednosti (od 0,99369 do 0,99909) s obzirom da je vrednost koeficijenta determinacije kod ostalih modela manja od 0,85383.


Prema tome model sa Levenberg–Marquardt-ovim algoritmom (*trainlm*) i model sa algoritmom koji koristi Bayes-ovu regularizaciju (*trainbr*) odabrani su za optimalne algoritme obučavanja neuronske mreže, pronalaženje optimalne arhitekture mreže i aproksimaciju eksperimentalnih rezultata. Uočava se da modeli neuronske mreže obučavani Levenberg–Marquardt-ovim algoritmom (*trainlm*) i algoritmom sa Bayes-ovom regularizacijom (*trainbr*) u NSM i SM režimu postižu manje srednje kvadratne greške pri većem broju neurona u skrivenom sloju nego ostali modeli što sugerise na znatnu kompleksnost mehanizama koji doprinose padu fluksa kako je i procenjeno postavljanjem hipoteze ove doktorske disertacije.

Optimalan broj neurona u skrivenom sloju zavisi od promene vrednosti koeficijenta determinacije i upoređivanje te informacije sa promenom srednje kvadratne greške vršeno je polazeći od osnovnog cilja optimalne arhitekture neuronske mreže: dobiti što jednostavniju mrežu, odnosno mrežu sa minimalnim brojem skrivenih neurona koja daje maksimalni koeficijent determinacije i minimalnu srednju kvadratnu grešku.

Prema slici 6.1.1. koja prikazuje varijaciju srednje kvadratne greške podataka za testiranje mreže u NSM režimu za Levenberg–Marquardt-ov algoritam (*trainlm*) i algoritam Bayes-ove regularizacije (*trainbr*) može se videti da povećanjem broja neurona do 6 u skrivenom sloju svi modeli ukazuju na lošu prediktivnu sposobnost, odnosno testni podaci imaju najveću grešku za oba algoritma i obe prenosne funkcije. Dalje povećanje broja skrivenih neurona rezultuje boljom sposobnošću predviđanja pošto se srednja kvadratna greška približava ciljnoj graničnoj vrednosti postavljenoj za trening.

Kada je dostignuto 8 neurona u skrivenom sloju u slučaju Levenberg–Marquardt-ovog algoritma sa sigmoidalnom hiperboličnom funkcijom (*trainlm tansig*) zapaža se blagi

neznaatni pad, skoro stagnacija srednje kvadratne greške. S toga se može reći da dalje povećanje broja neurona ne doprinosi značajno poboljšanju predikcije mreže tako da se može usvojiti arhitektura mreže sa jednim skrivenim slojem u kom se nalazi 8 neurona.

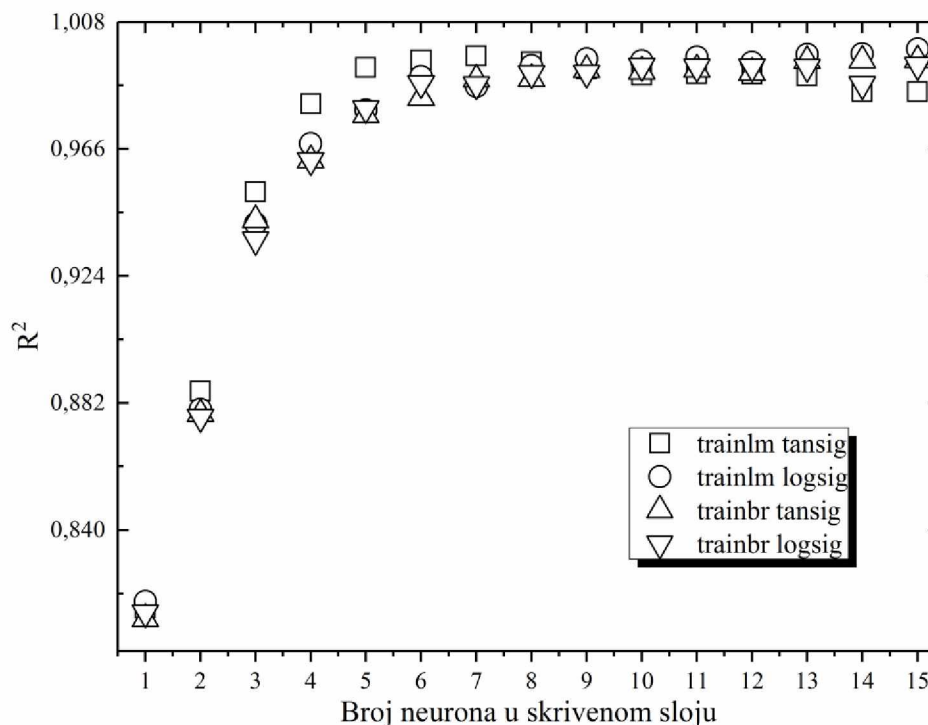


Slika 6.1.1. Varijacija vrednosti srednje kvadratne greške sa brojem neurona skrivenog sloja mikrofiltracije kultivacione smeše *Streptomyces hygroscopicus* u uslovima ugušćivanja u NSM režimu

Za 8 neurona u skrivenom sloju vrednost srednje kvadratne greške Levenberg–Marquardt-ovog algoritma sa sigmoidalnom hiperboličnom funkcijom (*trainlm tansig*) iznosi $3,53 \cdot 10^{-4}$, dok koeficijent determinacije (slika 6.1.2.) ima vrednost od 0,99477. U slučaju korišćenja Levenberg–Marquardt-ov algoritma sa sigmoidalnom logističkom funkcijom (*trainlm logsig*) dolazi do neznaatnog variranja srednje kvadratne greške za više od 6 neurona. Međutim, posmatrajući vrednosti koeficijenta determinacije (slika 6.1.2.) može se reći da je veća vrednost dobijena za 8 neurona u skrivenom sloju koja iznosi 0,99353.

U modelu neuronske mreže koji koristi algoritam Bayes-ove regularizacije sa hiperboličnom sigmoidalnom funkcijom (*trainbr tansig*) takođe dolazi do blagog pada, skoro stagnacije srednje kvadratne greške nakon 8 neurona u skrivenom sloju. Posmatrajući sliku 6.1.2. sa povećanjem broja neurona u skrivenom sloju dolazi i do povećanja vrednosti koeficijenta determinacije, mada nakon 8 neurona u skrivenom sloju kriva pokazuje skoro linearnu zavisnost od broja neurona. Kako je cilj optimizacije mrežne strukture jednostavnija

arhitektura mreže, povećanje broja neurona koje rezultuje beznačajnim rastom koeficijenta determinacije je odbačeno. Vrednosti srednje kvadratne greške i koeficijenta determinacije iznose $6,98 \cdot 10^{-4}$ i 0,98903 respektivno. Za model Bayes-ove regularizacije sa logističkom sigmoidalnom funkcijom (*trainbr logsig*), takođe se uočava stagnacija vrednosti srednje kvadratne greške sa porastom broja neurona u skrivenom sloju iznad 8, tako da je i u ovom slučaju primenjeno pravilo jednostavnije strukture mreže. Za 8 neurona u skrivenom sloju vrednost srednje kvadratne greške iznosi $6,43 \cdot 10^{-4}$, dok je vrednost koeficijenta determinacije 0,99096.




Slika 6.1.2. Varijacija vrednosti koeficijenta determinacije sa brojem neurona skrivenog sloja mikrofiltracije kultivacione smeše *Streptomyces hygroscopicus* u uslovima ugušćivanja u NSM režimu

U SM režimu su dobijeni slični rezultati, međutim vrednosti koeficijenta determinacije odabranih modela neuronskih mreža su nešto veće u odnosu na eksperimente mikrofiltracije u NSM režimu, što ukazuje na preciznije predviđanje (prema slikama 6.1.2 i 6.1.4). Poređenjem promene vrednosti srednje kvadratne greške i koeficijenta determinacije sa promenom broja neurona u skrivenom sloju uočava se da povećanje broja skrivenih neurona rezultuje boljom sposobnošću predviđanja.

Posmatrajući promenu srednje kvadratne greške (slika 6.1.3.) kada je dostignuto 8 neurona u skrivenom sloju u slučaju Levenberg–Marquardt-ovog algoritma sa sigmoidalnom

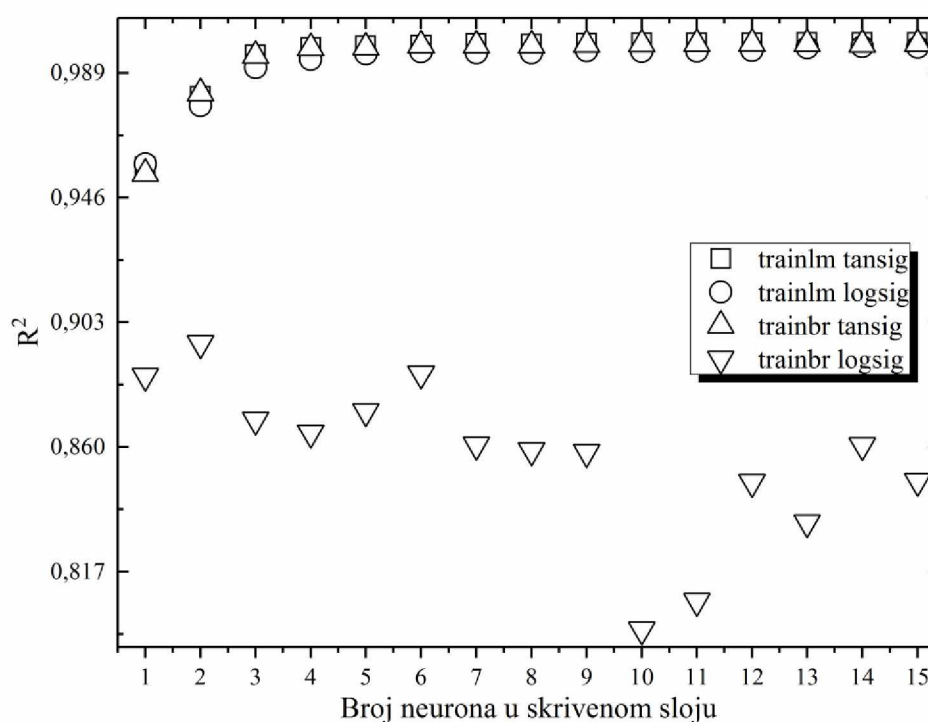
hiperboličnom funkcijom (*trainlm tansig*) jasno je uočljiv blagi nezatni rast, skoro stagnacija srednje kvadratne greške. S toga se može reći da dalje povećanje broja neurona ne doprinosi značajno poboljšanju predikcije mreže tako da se može usvojiti arhitektura mreže sa 8 neurona u jednon skrivenom sloju. Za 8 neurona u skrivenom sloju vrednost srednje kvadratne greške Levenberg–Marquardt-ovog algoritma sa sigmoidalnom hiperboličnom funkcijom (*trainlm tansig*) iznosi $7,61 \cdot 10^{-5}$, dok koeficijent determinacije (slika 6.1.4.) ima vrednost od 0,99836.

U slučaju korišćenja Levenberg–Marquardt-ovog algoritma sa sigmoidalnom logističkom funkcijom (*trainlm logsig*) dolazi do manjeg rasta srednje kvadratne greške za 9 neurona u skrivenom sloju, što može da ukaže na problem prekomernog treniranja. Međutim, posmatrajući vrednosti koeficijenta determinacije (slika 6.1.4.) može se reći da kod ovog algoritma treniranja i prenosne funkcije dolazi do stalnog rasta koeficijenta determinacije sa povećanjem broja neurona u skrivenom sloju. S toga je uzimajući pravilo jednostavnije arhitekture usvojena vrednost od 8 neurona u skrivenom sloju. Za 8 neurona u skrivenom sloju vrednost srednje kvadratne greške Levenberg–Marquardt-ovog algoritma sa sigmoidalnom logističkom funkcijom (*trainlm logsig*) iznosi $7,43 \cdot 10^{-5}$, dok koeficijent determinacije ima vrednost od 0,99598.



Slika 6.1.3. Varijacija srednje kvadratne greške sa brojem neurona u skrivenom sloju mikrofiltracije kultivacione smeše *Streptomyces hygroscopicus* u uslovima ugušćivanja u SM režimu

U modelu neuronske mreže koji koristi algoritam Bayes-ove regularizacije sa hiperboličnom sigmoidalnom funkcijom (*trainbr tansig*) dolazi do slabijeg opadanja srednje kvadratne greške nakon 7 neurona u skrivenom sloju. Posmatrajući sliku 6.1.3. primenom modela Bayes-ove regularizacije sa hiperboličnom sigmoidalnom funkcijom (*trainbr tansig*) uočavaju se nešto veće vrednosti srednje kvadratne greške u odnosu na vrednosti dobijene Levenberg–Marquardt-ovim algoritmom, što ukazuje na lošiju moć predviđanja.



Slika 6.1.4. Varijacija koeficijenta determinacije sa brojem neurona u skrivenom sloju mikrofiltracije kultivacione smeše *Streptomyces hygroscopicus* u uslovima ugušćivanja u SM režimu

Međutim, koeficijenti determinacije Bayes-ove regularizacije sa hiperboličnom sigmoidalnom funkcijom (*trainbr tansig*) i Levenberg–Marquardt-ovog algoritma sa hiperboličnom sigmoidalnom funkcijom (*trainlm tansig*) pokazuju skoro iste vrednosti. Kao i u prethodnom modelu, može se reći da u slučaju Bayes-ove regularizacije sa hiperboličnom sigmoidalnom funkcijom (*trainbr tansig*) povećanje broja neurona rezultuje beznačajnim rastom koeficijenta determinacije i ne doprinosi značajno poboljšanju predikcije mreže, pa se može usvojiti arhitektura mreže sa jednim skrivenim slojem u kom se nalazi 8 neurona. Vrednosti srednje kvadratne greške i koeficijenta determinacije za 8 neurona u skrivenom sloju Bayes-ove regularizacije sa hiperboličnom sigmoidalnom funkcijom (*trainbr tansig*)

iznose $9,49 \cdot 10^{-5}$ i $0,99856$, respektivno. Primećeno je da kod modela Bayes-ove regularizacije sa logističkom sigmoidalnom funkcijom (*trainbr logsig*) veći broj neurona povećava kompleksnost strukture veštačke neuronske mreže, ali značajno ne poboljšava ponašanje mreže. Na osnovu dobijenih rezultata može se izvesti zaključak da iako dolazi do poboljšanja performansi mreže, javlja se neodređena sposobnost generalizacije postavljene arhitekture neuronske mreže. Ovo se može objasniti time da veštačka neuronska mreža uči i tokom obuke i tokom testiranja, pa čak može ukazivati i na preveliku specijalizaciju modela zbog preobučavanja mreže.


Da bi se izbegao problem sa specijalizacijom mreže, a zadržala visoka predikcija optimalan broj neurona za aproksimaciju eksperimentalnih rezultata mikrofiltracije kultivacionih tečnosti na bazi mikroorganizama *Streptomyces hygroscopicus* sa i bez promotora turbulencije u uslovima koncentrisanja napojne smeše iznosi 8. Prema tome, optimalna arhitektura neuronske mreže je odabrana kao 4-8-1 sa hiperboličnom funkcijom prenosa i algoritmom treniranja Levenberg- Marquardt (*trainlm tansig*).

Aproksimirajući predikcionu moć neuronske mreže na ukupne eksperimentalne rezultate posmatrajući oba režima mikrofiltracije (sa i bez promotora turbulencije) dobijene su nešto veće vrednosti srednje kvadratne greške (Prilog 1, tabela P1.5) nego u pojedinačnim režimima. Ipak, povećanjem broja neurona u skrivenom sloju dolazi do pada srednje kvadratne greške (bliže postavljenoj ciljnoj vrednosti treninga) što ukazuje na dobru predikcionu sposobnost mreže. U slučaju Levenberg–Marquardt-ovog algoritma treninga kada je prenosna funkcija sigmoidalna hiperbolična (*trainlm tansig*), kao i u slučaju korišćenja sigmoidalne logističke prenosne funkcije pri istom algoritmu treniranja (*trainlm logsig*), minimalne vrednosti srednje kvadratne greške od $2,91 \cdot 10^{-4}$ i $2,96 \cdot 10^{-4}$ postignute su za 15 i 14 neurona u skrivenom sloju, respektivno. U slučaju korišćenja sigmoidalne hiperbolične prenosne funkcije pri treniranju mreže algoritmom koji koristi Bayes-ovu regularizaciju (*trainbr tansig*) minimalna vrednost srednje kvadratne greške od $5,96 \cdot 10^{-4}$ postignuta je za 12 neurona u skrivenom sloju. Daljim povećanjem broja neurona dolazi do neznatnog rasta minimalne srednje kvadratne greške, pa se može reći da i ovaj model pokazuje relativno zadovoljavajuću predikcionu sposobnost. Pri korišćenju algoritma Bayes-ove regularizacije sa logističkom sigmoidalnom prenosnom funkcijom (*trainbr logsig*), kao i algoritma rezilientnog povratnog prostiranja sa sigmoidalnom hiperboličnom prenosnom funkcijom (*trainrp tansig*) minimalna srednja kvadratna greška od $2,27 \cdot 10^{-4}$ i $3,98 \cdot 10^{-3}$, respektivno, postignuta je sa 14 neurona u skrivenom sloju, dok je pri algoritmu rezilientnog


povratnog prostiranja sa sigmoidalnom logističkom prenosnom funkcijom (*trainrp logsig*) minimalna srednja kvadratna greška od $3,87 \cdot 10^{-3}$ postignuta sa 12 neurona u skrivenom sloju. U slučaju korišćenja algoritma skaliranog konjugovanog gradijenta i sigmoidalne hiperbolične prenosne funkcije (*trainscg tansig*) minimalna srednja kvadratna greška od $6,02 \cdot 10^{-3}$ postignuta je sa 10 neurona u skrivenom sloju, dok je pri istom algoritmu u slučaju sigmoidalne logističke prenosne funkcije (*trainscg logsig*) minimalna srednja kvadratna greška od $6,89 \cdot 10^{-3}$ postignuta sa 6 neurona. Korišćenjem algoritma jednostepenog sekantnog povratnog prostiranja greške unazad i sigmoidalne hiperbolične funkcije (*trainoss tansig*) minimalna vrednost srednje kvadratne greške od $7,12 \cdot 10^{-3}$ postignuta je sa 9 neurona u skrivenom sloju, a u slučaju korišćenja sigmoidalne logističke funkcije (*trainoss logsig*) minimalna vrednost srednje kvadratne greške od $8,94 \cdot 10^{-3}$ postignuta je za 10 neurona u skrivenom sloju. Posmatrajući srednje kvadratne greške svih primenjenih algoritama najmanje vrednosti su postignute pri korišćenju Levenberg–Marquardt-ovog algoritma (*trainlm*) i algoritma sa Bayes-ovom regularizacijom (*trainbr*). Na osnovu toga se može zaključiti da vrednost srednje kvadratne greške kod ovih modela više konvergira postavljenoj ciljnoj vrednosti u odnosu na ostale modele, što ukazuje na bolju moć predviđanja, tako da su modeli neuronskih mreža obučeni ovim algoritmima određeni kao optimalni.

Na slici 6.1.5. koja prikazuje varijaciju srednje kvadratne greške (MSE) u odnosu na broj skrivenih neurona za optimalne algoritme obuke i vrstu prenosne funkcije na podacima za testiranje mreže može se videti da je u skrivenom sloju dovoljno imati deset neurona za adekvatno procenjivanje vrednosti fluksa permeata. Naime, u slučaju Levenberg–Marquardt-ovog algoritma sa hiperboličnom prenosnom funkcijom (*trainlm tansig*) nakon 10 neurona u skrivenom sloju ne dolazi do izraženog pada vrednosti srednje kvadratne greške. Takođe, prema slici 6.1.6. koja prikazuje promenu vrednosti koeficijenta determinacije sa promenom broja neurona u skrivenom sloju (Prilog 1, tabela P1.6) kod modela sa Levenberg–Marquardt-ovim algoritmom i hiperboličnom prenosnom funkcijom (*trainlm tansig*) više od 10 neurona u skrivenom sloju rezultira neznatnim povećanjem koeficijenta determinacije.

Rezultati sugerišu da povećanje broja neurona u skrivenom sloju ne doprinosi značajno poboljšanju predikcije mreže pa se može usvojiti arhitektura mreže sa jednim skrivenim slojem u kom se nalazi 10 neurona. Vrednosti srednje kvadratne greške i koeficijenta determinacije za 10 neurona u skrivenom sloju kod Levenberg–Marquardt-ovog algoritma sa hiperboličnom prenosnom funkcijom (*trainlm tansig*) iznose $4,80 \cdot 10^{-4}$ i 0,99651 respektivno.



Slika 6.1.5. Varijacija srednje kvadratne greške sa brojem neurona u skrivenom sloju mikrofiltracije kultivacione smeše *Streptomyces hygroscopicus* u uslovima ugušćivanja u oba režima



Slika 6.1.6. Varijacija koeficijenta determinacije sa brojem neurona u skrivenom sloju mikrofiltracije kultivacione smeše *Streptomyces hygroscopicus* u uslovima ugušćivanja u oba režima

U slučaju korišćenja Levenberg–Marquardt-ovog algoritma sa sigmoidalnom logističkom funkcijom (*trainlm logsig*) uočavaju se slični rezultati, odnosno povećanje broja neurona u skrivenom sloju iznad 10 ne ukazuje na značajan pad vrednosti srednje kvadratne greške niti značajan rast vrednosti koeficijenta determinacije. Za 10 neurona u skrivenom sloju vrednost srednje kvadratne greške Levenberg–Marquardt-ovog algoritma sa sigmoidalnom logističkom funkcijom (*trainlm logsig*) iznosi $5,61 \cdot 10^{-4}$, dok koeficijent determinacije ima vrednost od 0,99619.

U modelu neuronske mreže koji koristi algoritam Bayes-ove regularizacije sa hiperboličnom sigmoidalnom funkcijom (*trainbr tansig*) uočavaju se nešto veće vrednosti srednje kvadratne greške (slika 6.1.5) i nešto manje vrednosti koeficijenta determinacije (slika 6.1.6) u odnosu na vrednosti dobijene Levenberg–Marquardt-ovim algoritmom, što ukazuje na lošiju moć predviđanja. Optimalan broj neurona u skrivenom sloju je određen prema pravilu jednostavnije arhitekture mreže na 10 neurona. Vrednosti srednje kvadratne greške i koeficijenta determinacije za 10 neurona u skrivenom sloju Bayes-ove regularizacije sa hiperboličnom sigmoidalnom funkcijom (*trainbr tansig*) iznose $7,25 \cdot 10^{-4}$ i 0,99488 respektivno. Kod modela Bayes-ove regularizacije sa logističkom sigmoidalnom funkcijom (*trainbr logsig*) uočava se blagi pad vrednosti srednje kvadratne greške sa povećanjem broja neurona u skrivenom sloju iznad 10, dok koeficijent determinacije pokazuje iste vrednosti kao i kod modela sa hiperboličnom sigmoidalnom prenosnom funkcijom. S toga je optimalan broj neurona u skrivenom sloju određen na 10 prema pravilu jednostavnije strukture mreže. Za 10 neurona u skrivenom sloju vrednost srednje kvadratne greške iznosi $5,14 \cdot 10^{-4}$, dok je vrednost koeficijenta determinacije 0,99488. Kod ovog modela uočava se da su vrednosti srednje kvadratne greške manje nego kod modela Bayes-ove regularizacije sa hiperboličnom sigmoidalnom prenosnom funkcijom, tako da ovaj model pokazuje bolju predikcionu sposobnost.

Optimalan broj neurona za aproksimaciju eksperimentalnih rezultata mikrofiltracije kultivacionih tečnosti na bazi mikroorganizama *Streptomyces hygrosopicus* u uslovima koncentrisanja napojne smeše iznosi 10. Prema tome, optimalna arhitektura neuronske mreže je odabrana kao 4-10-1 sa hiperboličnom sigmoidalnom funkcijom prenosa i algoritmom treniranja Lavenberg-Marquardt (*trainlm tansig*), pošto su za ovaj model dobijene najveće vrednosti koeficijenta determinacije.


6.1.1. Validacija i verifikacija modela neuronske mreže u uslovima ugušćivanja

Sa ciljem utvrđivanja mogućnosti odabranog modela neuronske mreže da na osnovu zadatih ulaznih parametara pouzdano predvidi tehnološke pokazatelje procesa mikrofiltracije u okviru regresione analize razmatrana je korelacija između normalizovanih eksperimentalno dobijenih vrednosti fluksa permeata i normalizovanih vrednosti dobijenih modelom u režimu sa i bez statičkog promotora turbulencije. Validaciona procena je izvršena na skupu podataka za NSM i SM režim pošto su obučene neuronske mreže pokazale bolje rezultate sa manje neurona u skrivenom sloju. Težinski koeficijenti i koeficijenti praga utvrđeni tokom obuke su sačuvani, a zatim je mreža ponovo pokrenuta sa novim podacima. Kvalitet linearnog regresionog modela (odsečak postavljen u koordinatni početak) procenjen je preko Pearson-ovog koeficijenta i koeficijenta determinacije. Vrednosti Pearson-ovog korelacionog koeficijenta iznose 0,99967 i 0,99941 za normalizovane podatke promene fluksa tokom vremena u prisustvu statičkog promotora turbulencije i bez promotora tubulencije, respektivno. Visoke vrednosti koeficijenata korelacije ukazuju na pozitivnu korelaciju između eksperimentalnih podataka i podataka predviđenih neuronskom mrežom. Sa druge strane, vrednosti koeficijenta determinacije iznose 0,99935 za režim sa statičkim promotorom turbulencije i 0,99881 za režim bez statičkog promotora, što ukazuje da linearna regresiona jednačina ne može da objasni manje od 1% varijacija u sistemu.

Kako bi se izvršila kontrola dobijenih rezultata obučavanja projektovane neuronske mreže i na taj način potvrdila mogućnost generalizacije samog postupka primene ovih mreža za predviđanje mikrofiltracije kultivacione smeše *Streptomyces hygroscopicus* normalizovane eksperimentalno dobijene vrednosti fluksa permeata i normalizovane vrednosti dobijene modelom u režimu bez i sa statičkim promotorom turbulencije predstavljene su grafički. Prema slici 6.1.7. može se uočiti dobro slaganje vrednosti fluksa permeata izračunatih modelom neuronskih mreža sa eksperimentalnim vrednostima, pri čemu puna linija predstavlja idealno fitovanje linarnim modelom. Može se reći da je procedura učenja neuronske mreže bila efektivna i da su ulazno-izlazni podaci formirani na zadovoljavajući način.

Na osnovu rasporeda tačaka na dijagramu stvarnih i predviđenih vrednosti fluksa permeata (slika 6.1.7) uočava se nešto bolje fitovanje modela neuronske mreže u režimu sa statičkim promotorom turbulencije, što znači da je ustanovljena jača veza između stvarnih i

predviđenih vrednosti tehnoloških pokazatelja, odnosno formirani model bolje prati promene realnih vrednosti fluksa permeata tokom vremena.



Slika 6.1.7. Dijagram linearne regresije za mikrofiltraciju kultivacione smeše *Streptomyces hygrosopicus* u uslovima ugušćivanja: a) režim bez statičkog promotora turbulencije, b) režim sa statičkim promotorom turbulencije


Detaljnije upoređivanje rezultata svakog modela neuronske mreže izvršeno je analizom raspodele apsolutne relativne greške (tabela 6.1.1). Na osnovu ove analize za režim bez statičkog promotora turbulencije model neuronske mreže je bio u stanju predvideti 90% podataka sa greškom manjom od 10%, a samo 2 podatka (1%) su predviđena sa greškom većom od 20%. Za režim sa statičkim promotorom 100% podataka je predviđeno sa greškom manjom od 5%.

Do prljanja membrane dolazi već u početnoj fazi mikrofiltracije, što je imalo za posledicu brzi pad fluksa koji je zatim praćen sporim padom vrednosti fluksa do kraja procesa. Prisustvo promotora turbulencije unutar kanala membrane pojačava mešanje koje doprinosi odnošenju čestica sa filtracione pogače rezultujući smanjenim prljanjem membrane, te je pad fluksa sa vremenom manji kada se u sistem postavi statički mešač u poređenju sa sistemom bez mešača. Može se primetiti da je statički promotor turbulencije uvećao permeatni fluks sa oko 95 L/m²h u NSM režimu na oko 195 L/m²h u SM režimu (slika 6.1.8).

Tabela 6.1.1. Distribucija apsolutne relativne greške u uslovima ugušćivanja

Apsolutna relativna greška (%)		<1	<5	<10	<20	>20	suma
NSM režim	Broj podataka	64	110	25	19	2	220
	%	29	50	11	9	1	100
SM režim	Broj podataka	154	57	0	0	0	211
	%	73	27	0	0	0	100

Komparativnom analizom dobijenih simulacionih rezultata na eksperimentalnim podacima koji nisu bili predstavljeni neuronskoj mreži potvrđen je generalizacijski kapacitet modela neuronske mreže. Eksperimenti su izvršeni za oba režima mikrofiltracije pri transmembranskom pritisku od 0,9 bara, protoku napojne smeše 100 L/h i temperaturi od 30 °C, a zatim su predstavljeni neuronskoj mreži.



Slika 6.1.8. Verifikacija modela neuronske mreže za denormalizovane vrednosti fuksa permeata mikrofiltracije kultivacione smeše *Streptomyces hygroscopicus* u uslovima ugušćivanja: a) u režimu sa statičkim promotorom turbulencije, b) u režimu bez statičkog promotora turbulencije (Prilog 1, tabela P.1.7)

Kao što se može videti na slici 6.1.8. za oba režima mikrofiltracije neuronskom mrežom predviđeni fluks permeata se tačno poklapa sa rezultatima koji su dobijeni eksperimentom (Prilog 1, tabela P1.7). Ovim se dokazala i hipoteza istraživanja da se neuronskom mrežom može proceniti fluks permeata tokom vremena pri ugušćivanju kultivacione tečnosti *Streptomyces hygroscopicus* u uslovima kada je funkcionalni oblik povezanosti između ulaznih i izlaznih promenljivih nepoznat. Prema tome, moguće je unosom parametara procesa mikrofiltracije izračunati promenu fluksa permeata tokom vremena, što omogućava pristup optimizaciji procesa.

6.1.2. Relativni značaj ulaznih promenljivih u uslovima ugušćivanja

Neuronske mreže koristeći raspoložive eksperimentalne podatke predviđaju odnose između ulaznih i izlaznih parametara što je od izuzetne važnosti u slučajevima kada nije određena ili nije dobro formulisana njihova funkcionalna zavisnost. Međutim, ovi modeli (tzv. modeli crne kutije) ne pružaju informacije o mehanizmima koji se odvijaju u procesu modelovanom neuronskom mrežom, bolje rečeno ne pružaju informacije o uticaju različitih faktora na proces i njihovim međusobnim interakcijama, što je i glavni nedostatak ovih modela. S toga je razdvajanjem apsolutnih vrednosti sinaptičkih težina svakog skrivenog neurona u komponente koje su povezane sa svakim ulazom u neuronsku mrežu izvršeno kvantifikovanje uticaja pojedinih ulaznih promenljivih na izlazna svojstva modela. Za izračunavanje i opisivanje doprinosa pocesnih parametara u neuronskoj mreži primenjena je sledeća jednačina (Garson, 1991):

$$v = \frac{\sum_{j=1}^{n_h} \left[\frac{i_{vj}}{\sum_{k=1}^{n_v} i_{kj}} O_j \right]}{\sum_{i=j}^{n_v} \left[\sum_{j=1}^{n_h} \left(\frac{i_{vj}}{\sum_{k=1}^{n_v} i_{kj}} O_j \right) \right]} \quad (6.1.)$$

Gde su: v – relativni uticaj ulazne promenljive, n_v – broj ulaznih neurona, n_h – broj skrivenih neurona, i_j – apsolutne vrednosti jačine sinapsi između ulaznih i skrivenih neurona i O_j – apsolutne vrednosti jačine sinapsi između skrivenih neurona i neurona u izlaznom sloju.

Tabela 6.1.2. Relativni značaj ulaznih promenljivih u uslovima ugušćivanja

Ulazni podaci	NSM režim		SM režim	
	Stepen značajnosti	Rang	Stepen značajnosti	Rang
	(%)		(%)	
Transmembranski pritisak	7,43	4	10,94	4
Protok napojne smeše	13,36	2	22,56	2
Temperatura	11,59	3	12,90	3
Vreme mikrofiltracije	67,62	1	53,60	1
UKUPNO:	100		100	

Iz tabele 6.1.2. može se videti da vreme filtracije ima najvažniju ulogu u određivanju pada fluksa permeata kod oba režima mikrofiltracije (oko 68% u režimu bez statičkog promotora turbulencije i oko 54% u režimu sa statičkim promotorom turbulencije). Ovakvi rezultati su u korelaciji sa rezultatima drugih istraživača. Naime, istraživanjem unakrsne mikrofiltracije smeše fosfata i letećeg pepela doprinos vremena filtracije, kao ulazne promenljive neuronske mreže utvrđen je sa stepenom značajnosti uticaja na fluks permeata u opsegu 40-50% koji je objašnjen povećanim prljanjem mikrofiltracione membrane tokom vremena (Aydiner i sar., 2005). S druge strane u istraživanjima unakrsne mikrofiltracije polidisperznih suspenzija utvrđeno je da vreme filtracije predstavlja najznačajniji faktor uticaja pada fluksa permeata u svim ispitivanim slučajevima sa stepenom uticaja od 20% do 40% (Ghandehari i sar., 2011).

Sledeći faktor po važnosti je protok napojne smeše, čiji se doprinos za oko 40% povećava ukoliko se statički promotor turbulencije postavi u membranski kanal. Prisustvo promotora turbulencije unutar kanala membrane kroz koji protiče napojna suspenzija dovodi do promena u načinu proticanja, a spiralna komponenta Kenics statičkog mešača pojačava radijalno mešanje uslovljavajući kretanje struje fluida bliže površini membrane što povećava brzinu smicanja na površini membrane. U isto vreme, promena u obrascu protoka suspenzije kroz membranski kanal utiče i na porast uticaja transmembranskog pritiska koji je 32% veći za režim sa statičkim promotorom. Ovo se može objasniti većom osetljivošću statičkog promotora turbulencije na promenu brzine protoka suspenzije i transmembranskog pritiska usled promene obrasca protoka kroz membranski kanal (Krstić i sar., 2004). Geometrija helikoidnih elemenata Kenics statičkog mešača koji su postavljeni pod uglom od 90° u odnosu jedan na drugi pojačava radijalno mešanje izazivajući lokalne vrtloge u spiralama

mešača dovodeći do pojave sekundarnih tokova što zauzvrat povećava brzinu smicanja na površini membrane. Ova pojava rezultuje smanjenim nakupljanjem filtracione pogače, pa je time i efekat transmembranskog pritiska izraženiji. Pojačan uticaj protoka napojne suspenzije i transmembranskog pritiska usled postavljanja statičkog promotora turbulencije potvrđen je istraživanjima primene metode odzivne površine za modelovanje mikrofiltracije (Jokić i sar., 2010, Šereš i sar., 2018). U modelovanju fluksa permeata značajan uticaj ima i temperatura, mada je u režimu sa statičkim promotorom turbulencije ovaj uticaj nešto veći (11,59% u režimu bez statičkog promotora turbulencije i 12,90% u režimu sa statičkim promotorom turbulencije).

6.2. Modelovanje mikrofiltracije u uslovima recirkulacije napojne smeše

Kao i kod mikrofiltracije u uslovima koncentrisanja napojne smeše i u slučaju mikrofiltracije sa recirkulacijom napojne suspenzije za obradu podataka odabran je model neuronske mreže sa 1 skrivenim slojem neurona. Ukupno je testirano 10 modela neuronske mreže formiranih kombinacijom pet algoritama obuke (*trainlm*, *trainbr*, *trainrp*, *trainscg* i *trainoss*) i dva tipa prenosne funkcije (*tansig* i *logsig*) između ulaznog i skrivenog sloja (tabela 5.2.1) koji su varirani tokom obuke neuronske mreže do pronalaženja optimalne arhitekture. Kao prenosna funkcija između skrivenog i izlaznog sloja odabrana je linearna aktivaciona funkcija (tabela 5.2.1).

Broj neurona u ulaznom sloju određen je na osnovu broja parametara variranih tokom eksperimenta mikrofiltracije (tabela 5.1.2) uz dodatan parametar, vreme trajanja mikrofiltracije, a izuzimajući parametar temperature. Broj neurona u izlaznom sloju određen je prema promenljivoj koja se kao funkcija ulaznih promenljivih predviđa, odnosno izlazna promenljiva je promena vrednosti fluksa tokom vremena. Pre obučavanja, eksperimentalni podaci su normalizovani primenom jednačine 5.5., a zatim su randomizovani u tri grupe: 70% za trening, 15% za verifikaciju i 15% za testiranje kako je navedeno u poglavlju 5.2. (tabela 5.2.2). Kriterijumi prekidanja obučavanja mreže istovetni su kriterijumima primenjenim za slučaj ugušćivanja. Maksimalni broj epoha je postavljen na 1500, minimalna srednja kvadratna greška na 0, a najmanji gradijent učinka na $1 \cdot 10^{-10}$. Broj neurona u skrivenom sloju postepeno je povećavan počevši od minimalne strukture sa jednim neuronom i ispitivanjem postignutih rezultata, minimalne srednje kvadratne greške i koeficijenta determinacije, za svaki od režima mikrofiltracije (rezultati za režim bez statičkog promotora turbulencije prikazani su u Prilogu 2, tabele P2.1 i P2.2, a za režim sa statičkim promotorom turbulencije u Prilogu 2, tabele P2.3 i P2.4).

Za skup podataka mikrofiltracije bez upotrebe statičkog promotora turbulencije (NSM režim) model neuronske mreže sa 1 neuronom u skrivenom sloju pri korišćenju algoritma jednostepenog sekantnog povratnog prostiranja greške unazad i sigmoidalne hiperbolične funkcije (*trainoss tansig*) i istog algoritma sa sigmoidalnom logističkom funkcijom (*trainoss logsig*) dao je minimalnu srednju kvadratnu grešku od $2,38 \cdot 10^{-2}$ i $2,43 \cdot 10^{-2}$, respektivno. U slučaju korišćenja algoritma skaliranog konjugovanog gradijenta i sigmoidalne hiperbolične prenosne funkcije (*trainscg tansig*) minimalna srednja kvadratna greška od $1,99 \cdot 10^{-2}$ postignuta je sa 7 neurona u skrivenom sloju, dok je pri istom algoritmu u slučaju

sigmoidalne logističke prenosne funkcije (*trainscg logsig*) minimalna srednja kvadratna greška od $2,17 \cdot 10^{-2}$ postignuta sa svega 2 neurona u skrivenom sloju. Daljim povećanjem neurona u skrivenom sloju dolazi do rasta srednje kvadratne greške. Očigledno je da mreža trenirana algoritmom jednostepenog sekantnog povratnog prostiranja greške unazad sa obe prenosne funkcije (*trainoss tansig*, *trainoss logsig*), kao i algoritmom skaliranog konjugovanog gradijenta sa sigmoidalnom logističkom prenosnom funkcijom (*trainscg logsig*) nije u stanju aproksimirati zadate nelinearne odnose na ispravan način. U slučaju korišćenja algoritma rezilientnog povratnog prostiranja i sigmoidalne hiperbolične prenosne funkcije (*trainrp tansig*) postignuta je minimalna vrednost srednje kvadratne greške od $2,48 \cdot 10^{-2}$ za 5 neurona u skrivenom sloju, dok je pri korišćenju algoritma rezilientnog povratnog prostiranja i sigmoidalne logističke prenosne funkcije (*trainrp logsig*) minimalna vrednost srednje kvadratne greške od $2,03 \cdot 10^{-2}$ postignuta za 11 neurona u skrivenom sloju. U slučaju korišćenja Levenberg–Marquardt-ovog algoritma sa sigmoidalnom hiperboličnom prenosnom funkcijom (*trainlm tansig*) i istog algoritma sa sigmoidalnom logističkom prenosnom funkcijom (*trainlm logsig*) minimalna vrednost srednje kvadratne greške od $7,93 \cdot 10^{-5}$ postignuta je za 14 neurona u skrivenom sloju, odnosno $9,97 \cdot 10^{-5}$ za 13 neurona u skrivenom sloju. Pri korišćenju sigmoidalne hiperbolične prenosne funkcije i algoritma koji koristi Bayes-ove regularizaciju (*trainbr tansig*) i sigmoidalne logističke prenosne funkcije pri istom algoritmu treniranja (*trainbr logsig*) minimalna vrednost srednje kvadratne greške od $8,64 \cdot 10^{-5}$ i $9,46 \cdot 10^{-5}$, respektivno, postignuta je za 15 neurona u skrivenom sloju. Uočava se da modeli sa algoritmom rezilientnog povratnog prostiranja sa obe prenosne funkcije (*trainrp tansig* i *trainrp logsig*) i model sa algoritmom skaliranog konjugovanog gradijenta i sigmoidalnom hiperboličnom prenosnom funkcijom (*trainscg logsig*) pokazuju veću vrednosti srednje kvadratne greške u odnosu na Levenberg–Marquardt-ov algoritam treninga i Bayes-ovu regularizaciju, pa su zbog lošije sposobnosti generalizacije odbačeni iz daljeg razmatranja.

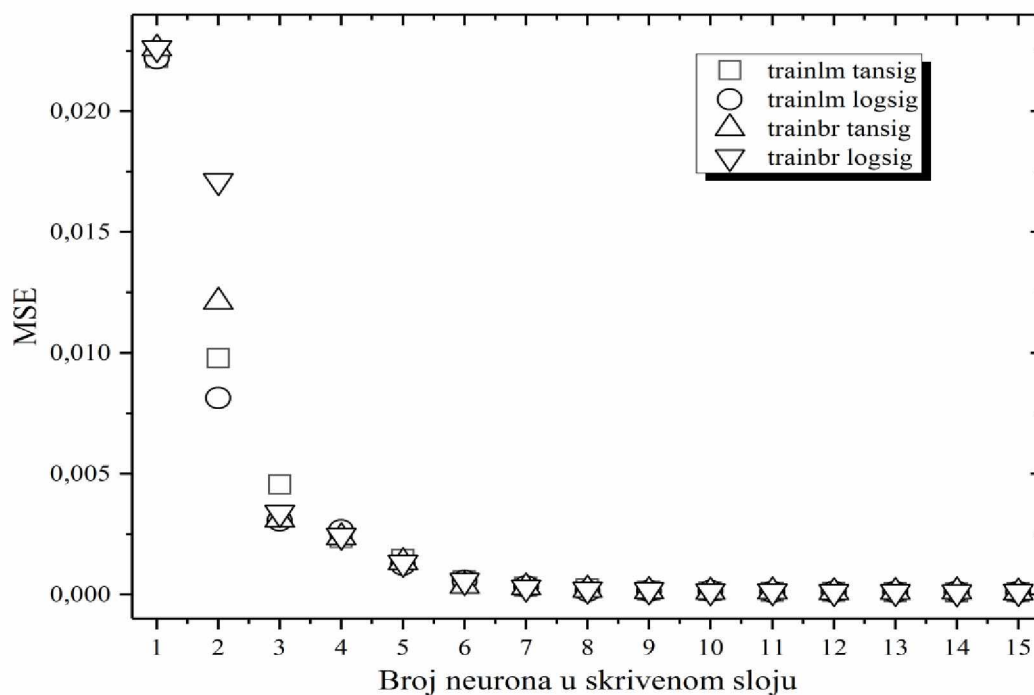
Na osnovu podataka za proveru u slučaju mikrofiltracije sa statičkim promotorom turbulencije (SM režim) model sa algoritmom rezilientnog povratnog prostiranja sa sigmoidalnom hiperboličnom prenosnom funkcijom (*trainrp tansig*), model sa algoritmom skaliranog konjugovanog gradijenta i sigmoidalnom hiperboličnom prenosnom funkcijom (*trainscg tansig*), model sa istim algoritmom i sigmoidalnom logističkom funkcijom (*trainscg logsig*) i modeli sa algoritmom jednostepenog sekantnog povratnog prostiranja greške unazad i obe prenosne funkcije (*trainoss tansig* i *trainoss logsig*) postižu minimalne vrednosti

srednje kvadratne greške od $2,09 \cdot 10^{-2}$, $3,52 \cdot 10^{-3}$, $4,31 \cdot 10^{-3}$, $5,06 \cdot 10^{-2}$ i $5,30 \cdot 10^{-2}$, respektivno. Red veličine srednje kvadratne greške kod Levenberg–Marquardt-ovog algoritma i obe prenosne funkcije (*trainlm tansig* i *trainlm logsig*), algoritma rezilientnog povratnog prostiranja sa sigmoidalnom logističkom prenosnom funkcijom (*trainrp logsig*) i algoritma sa Bayes-ovom regularizacijom i obe prenosne funkcije (*trainbr tansig* i *trainbr logsig*) iznosi $1 \cdot 10^{-4}$, tako da se može zaključiti da algoritmi sa srednjom kvadratnom greškom reda veličine $1 \cdot 10^{-3}$ i $1 \cdot 10^{-2}$ ne postižu dobre predikcione sposobnosti. Kako model sa algoritmom rezilientnog povratnog prostiranja i logističkom prenosnom funkcijom (*trainrp logsig*) postiže veću vrednost minimalne srednje kvadratne greške (od $6,19 \cdot 10^{-4}$) nego modeli sa Levenberg–Marquardt-ovim algoritmom i algoritmom koji koristi Bayes-ovu regularizaciju odbačen je iz daljeg razmatranja.


Na osnovu prethodne analize u oba režima mikrofiltracije sa recirkulacijom napojne smeše model sa Levenberg–Marquardt-ovim algoritmom i model sa algoritmom koji koristi Bayes-ovu regularizaciju daju najmanju srednju kvadratnu grešku tako da su odabrani za optimalne algoritme obuke neuronske mreže i pronalaženje optimalne arhitekture.

Prema slici 6.2.1. uočava se da model sa Levenberg–Marquardt-ovim algoritmom i sigmoidalnom hiperboličnom funkcijom (*trainlm tansig*) na podacima za testiranje mreže u NSM režimu pokazuje skoro linearnu zavisnost srednje kvadratne greške sa porastom broja neurona u skrivenom sloju više od 10, uz neznatan rast srednje kvadratne greške sa 12 neurona u skrivenom sloju. S toga na osnovu koeficijenta determinacije (slika 6.2.2.) čija vrednost raste sa porastom broja neurona u skrivenom sloju za optimalan broj neurona u skrivenom sloju je usvojeno 11 neurona. Vrednost srednje kvadratne greške za 11 neurona u skrivenom sloju Levenberg–Marquardt-ovog algoritma sa sigmoidalnom hiperboličnom funkcijom (*trainlm tansig*) iznosi $1,05 \cdot 10^{-4}$, dok je vrednost koeficijenta determinacije 0,99886.

Skoro linearna zavisnost vrednosti srednje kvadratne greške nakon 11 neurona u skrivenom sloju (slika 6.2.1.) uočava se i u slučaju korišćenja Levenberg–Marquardt-ovog algoritma sa sigmoidalnom logističkom funkcijom (*trainlm logsig*), kao i linearna zavisnost vrednosti koeficijenta determinacije (slika 6.2.2.). S toga se može reći da povećanje broja neurona više od 11 ne doprinosi značajno poboljšanju predikcije mreže, tako da je ovaj broj neurona usvojen za optimalan broj neurona u skrivenom sloju. Vrednosti srednje kvadratne greške i koeficijenta determinacije iznose $1,16 \cdot 10^{-4}$ i 0,99873, respektivno za Levenberg–Marquardt-ov algoritam sa sigmoidalnom logističkom funkcijom (*trainlm logsig*).



Slika 6.2.1. Varijacija vrednosti srednje kvadratne greške sa brojem neurona skrivenog sloja mikrofiltracije kultivacione tečnosti *Bacillus velezensis* u uslovima recirkulacije napojne smeše u NSM režimu



Slika 6.2.2. Varijacija koeficijenta determinacije sa brojem neurona skrivenog sloja mikrofiltracije kultivacione tečnosti *Bacillus velezensis* u uslovima recirkulacije napojne smeše u NSM režimu

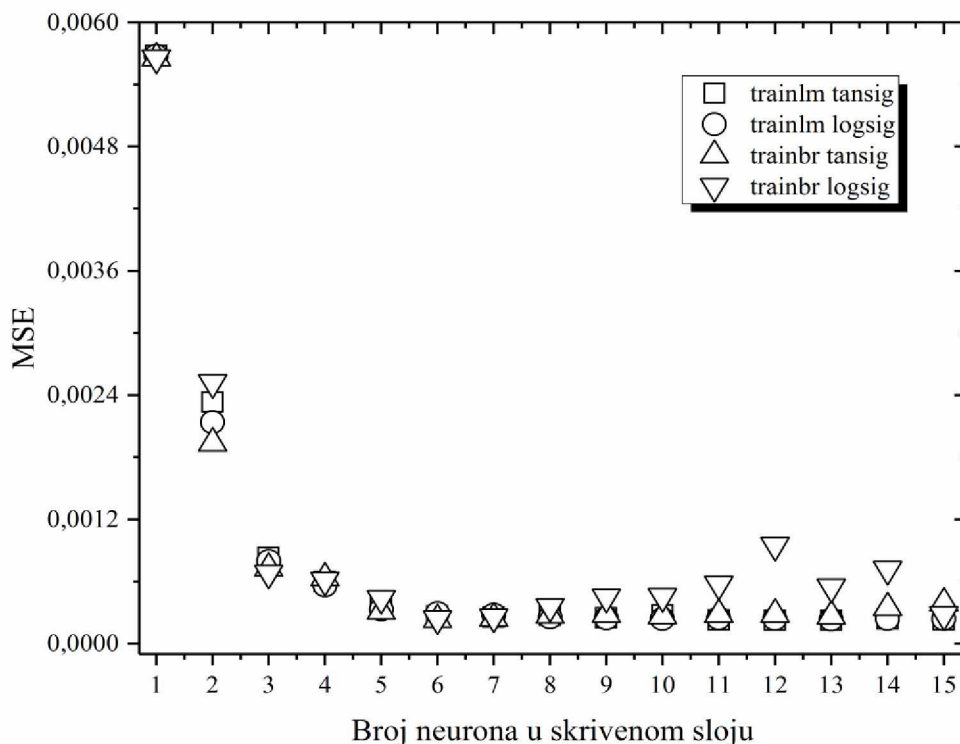
Za model Bayes-ove regularizacije sa hiperboličnom sigmoidalnom funkcijom (*trainbp tansig*) uočava se povremeni rast i pad vrednosti srednje kvadratne greške sa porastom broja neurona u skrivenom sloju iznad 10. Isto ponašanje mreže se uočava i kod vrednosti koeficijenta determinacije. S toga se može zaključiti da model neuronske mreže pokazuje određenu nesposobnost generalizacije što može ukazati da je mreža naučila detalje u podacima za obuku, ali ne i ulazno-izlazne veze između promenljivih. Posmatrajući sliku 6.2.1. primenom modela Bayes-ove regularizacije sa logističkom sigmoidalnom funkcijom (*trainbp logsig*) uočava se konstantni pad vrednosti srednje kvadratne greške sa povećanjem broja neurona što ukazuje na dobre prediktivne sposobnosti mreže. S toga je optimalan broj neurona u skrivenom sloju procenjen na osnovu vrednosti koeficijenta determinacije koji raste do 11 neurona u skrivenom sloju, a zatim dolazi do skoro linearne zavisnosti između koeficijenta determinacije i broja neurona. Može se reći da dalje povećanje broja neurona ne doprinosi značajno poboljšanju predikcije mreže tako da se može primeniti pravilo jednostavnije arhitekture mreže sa jednim skrivenim slojem u kom se nalazi 11 neurona. Za 11 neurona u skrivenom sloju vrednost srednje kvadratne greške modela Bayes-ove regularizacije sa logističkom sigmoidalnom funkcijom (*trainbp logsig*) iznosi $1,36 \cdot 10^{-4}$, dok je vrednost koeficijenta determinacije 0,99853. Posmatrajući vrednost srednje kvadratne greške modela sa Bayes-ovom regularizacijom uočavaju se veće vrednosti u odnosu na vrednosti dobijene Levenberg–Marquardt-ovim algoritmom, što ukazuje na lošiju moć predviđanja. Isto ponašanje modela Bayes-ove regularizacije sa logističkom sigmoidalnom funkcijom (*trainbp logsig*) uočeno je i u uslovima koncentrisanja napojne smeše. Upoređujući koeficijente determinacije sva četiri optimalna modela (slika 6.2.2.) uočava se da Levenberg–Marquardt-ov algoritam sa sigmoidalnom hiperboličnom funkcijom (*trainlm tansig*) daje najveće vrednosti koeficijenta determinacije za isti broj optimalnih neurona u skrivenom sloju. Iz tog razloga je ovaj model određen kao optimalni za režim mikrofiltracije bez statičkog promotora turbulencije.

U SM režimu su dobijeni slični rezultati, međutim vrednosti koeficijenta determinacije odabranih modela neuronskih mreža su nešto manje u odnosu na eksperimente mikrofiltracije u NSM režimu, što ukazuje na lošije predviđanje (prema slikama 6.2.2. i 6.2.4). Vrednost srednje kvadratne greške (slika 6.2.3.) modela sa Levenberg–Marquardt-ovim algoritmom sa sigmoidalnom hiperboličnom funkcijom (*trainlm tansig*) opada sa povećanjem broja neurona u skrivenom sloju do dostizanja 11 neurona u skrivenom sloju. Daljim povećanjem neurona u skrivenom sloju jasno je uočljiv blagi rast, skoro stagnacija srednje kvadratne greške, pa se


može reći da dalje povećanje broja neurona ne doprinosi značajno poboljšanju predikcije mreže i usvojiti arhitektura mreže sa jednim skrivenim slojem u kom se nalazi 11 neurona. Za 11 neurona u skrivenom sloju vrednost srednje kvadratne greške Levenberg–Marquardt-ovog algoritma sa sigmoidalnom hiperboličnom funkcijom (*trainlm tansig*) iznosi $2,30 \cdot 10^{-4}$, dok koeficijent determinacije (slika 6.2.4.) ima vrednost od 0,99563. U slučaju korišćenja Levenberg–Marquardt-ovog algoritma sa sigmoidalnom logističkom funkcijom (*trainlm logsig*) model neuronske mreže se ponaša slično prethodnom modelu tako da je usvojen optimalan broj od 11 neurona u skrivenom sloju. Za 11 neurona u skrivenom sloju vrednost srednje kvadratne greške Levenberg–Marquardt-ovog algoritma sa sigmoidalnom logističkom funkcijom (*trainlm logsig*) iznosi $2,44 \cdot 10^{-4}$, dok koeficijent determinacije ima vrednost od 0,99543. Na slici 6.2.3. uočava se manja vrednost srednje kvadratne greške modela mreže obučene Levenberg–Marquardt-ovim algoritmom sa sigmoidalnom hiperboličnom funkcijom u odnosu na vrednosti koje postiže model istog algoritma obučavanja sa logističkom prenosnom funkcijom za isti optimalan broj neurona, što ukazuje na lošiju moć predviđanja.

U modelu neuronske mreže koji koristi algoritam Bayes-ove regularizacije sa hiperboličnom sigmoidalnom funkcijom (*trainbr tansig*) zapaža se neznatan rast, skoro linearna zavisnost srednje kvadratne greške nakon 7 neurona u skrivenom sloju (slika 6.2.3.). Vrednost koeficijenta determinacije (slika 6.2.4.) pokazuje manji pad nakon 7 neurona u skrivenom sloju tako da se može zaključiti da veći broj neurona u skrivenom sloju ne doprinosi značajno poboljšanju predikcije mreže. Vrednosti srednje kvadratne greške i koeficijenta determinacije modela Bayes-ove regularizacije sa hiperboličnom sigmoidalnom funkcijom (*trainbr logsig*) za 7 neurona u skrivenom sloju iznose $2,46 \cdot 10^{-4}$ i 0,99514, respektivno.

Model Bayes-ove regularizacije sa hiperboličnom sigmoidalnom funkcijom (*trainbr tansig*) za isti broj neurona daje veće vrednosti srednje kvadratne greške u odnosu na rezultate dobijene Levenberg–Marquardt-ovim algoritmom sa hiperboličnom sigmoidalnom funkcijom (*trainlm tansig*). Čak poredeći vrednosti srednje kvadratne greške pri optimalnom broju neurona ova dva modela takođe se uočava veća vrednost kod modela mreže Bayes-ove regularizacije sa hiperboličnom sigmoidalnom funkcijom (*trainbr tansig*). S toga se može zaključiti da model Bayes-ove regularizacije sa hiperboličnom sigmoidalnom funkcijom pokazuje lošiju moć predviđanja.



Slika 6.2.3. Varijacija vrednosti srednje kvadratne greške sa brojem neurona skrivenog sloja mikrofiltracije kultivacione tečnosti *Bacillus velezensis* u uslovima recirkulacije napojne smeše u SM režimu



Slika 6.2.4. Varijacija vrednosti koeficijenta determinacije sa brojem neurona skrivenog sloja mikrofiltracije kultivacione tečnosti *Bacillus velezensis* u uslovima recirkulacije napojne smeše u SM režimu

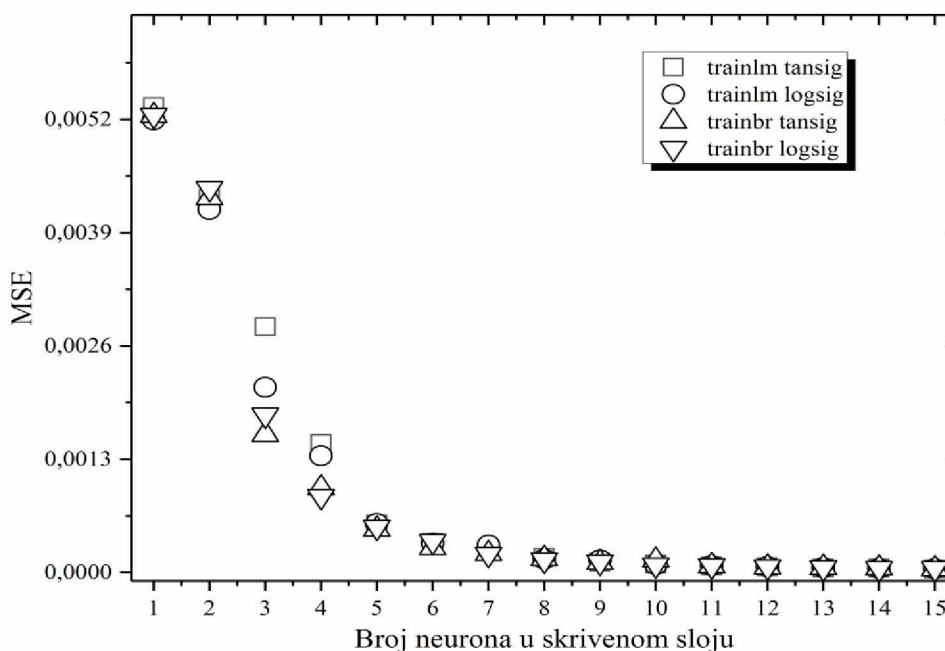
Vrednosti srednje kvadratne greške i koeficijenta determinacije modela mreže Bayesian regularizacije sa hiperboličnom sigmoidalnom funkcijom (*trainbr logsig*) za 7 neurona u skrivenom sloju iznose $2,46 \cdot 10^{-4}$ i 0,99514, respektivno.

U slučaju modela Bayes-ove regularizacije sa logističkom sigmoidalnom funkcijom (*trainbr logsig*) može se reći da povećanje broja neurona u skrivenom sloju više od 3 dovodi do rasta vrednosti srednje kvadratne greške, odnosno pada vrednosti koeficijenta determinacije. Vrednosti srednje kvadratne greške i koeficijenta determinacije modela mreže Bayes-ove regularizacije sa logističkom sigmoidalnom funkcijom (*trainbr logsig*) za 3 neurona u skrivenom sloju iznose $6,13 \cdot 10^{-4}$ i 0,98861, respektivno. Uočava se da mreža pokazuje lošiju sposobnost predviđanja u odnosu na model Levenberg–Marquardt-ovog algoritma sa hiperboličnom sigmoidalnom funkcijom (*trainlm tansig*) pošto su vrednosti srednje kvadratne greške veće, a vrednosti koeficijenta determinacije manje.


Na osnovu prethodnog zaključuje se da je u režimu mikrofiltracije sa statičkim promotorom turbulencije model sa 11 neurona u skrivenom sloju treniran Levenberg–Marquardt-ovim algoritmom sa logističkom sigmoidalnom funkcijom (*trainlm logsig*) optimalan, pošto vrednost srednje kvadratne greške i koeficijenta determinacije više konvergira postavljenoj ciljnoj vrednosti u odnosu na ostale modele, što ukazuje na bolju moć predviđanja. Prema tome, optimalna arhitektura neuronske mreže za aproksimaciju eksperimentalnih rezultata mikrofiltracije kultivacionih tečnosti na bazi mikroorganizama *Bacillus velezensis* u uslovima recirkulacije napojne smeše sa i bez promotora turbulencije je odabrana kao 3-11-1 sa logističkom sigmoidalnom funkcijom prenosa i algoritmom treniranja Levenberg- Marquardt (*trainlm logsig*).

Analizom predikcione sposobnosti neuronske mreže na ukupnim eksperimentalnim rezultatima (Prilog 2, tabele P.2.5 i P.2.6) posmatrajući oba režima mikrofiltracije (sa i bez promotora turbulencije) kao i u pojedinačnim režimima mikrofiltracije uočava se da modeli sa algoritmom rezilientnog povratnog prostiranja (*trainrp tansig* i *trainrp logsig*), modeli sa algoritmom skaliranog konjugovanog gradijenta (*trainscg tansig* i *trainscg logsig*), modeli sa algoritmom jednostepenog sekantnog prostiranja greške unazad (*trainoss tansig* i *trainoss logsig*) postižu veći red veličine srednje kvadratne greške, koji iznosi $1 \cdot 10^{-3}$, u odnosu na modele sa Levenberg–Marquardt-ovim algoritmom treninga i Bayes-ovom regularizacijom koji postižu red veličine srednje kvadratne greške od $1 \cdot 10^{-5}$. Iz tog razloga modeli sa Levenberg–Marquardt-ovim algoritmom i algoritmom koji koristi Bayes-ovu regularizaciju su određeni za optimalne.

Prema slici 6.2.5. u slučaju Levenberg–Marquardt-ovog algoritma sa hiperboličnom prenosnom funkcijom (*trainlm tansig*) nakon 13 neurona u skrivenom sloju ne dolazi do izraženog pada vrednosti srednje kvadratne greške, a ni rasta koeficijenta determinacije. Ovi rezultati sugerišu da povećanje broja neurona u skrivenom sloju ne doprinosi značajno poboljšanju predikcije mreže, tako da se može usvojiti jednostavnija arhitektura mreže sa skrivenim slojem u kom se nalazi 13 neurona. Vrednosti srednje kvadratne greške i koeficijenta determinacije za 13 neurona u skrivenom sloju kod Levenberg–Marquardt-ovog algoritma sa hiperboličnom prenosnom funkcijom (*trainlm tansig*) iznose $4,83 \cdot 10^{-5}$ i 0,99917, respektivno. U slučaju korišćenja Levenberg–Marquardt-ovog algoritma sa sigmoidalnom logističkom funkcijom (*trainlm logsig*) uočavaju se slični rezultati, odnosno povećanje broja neurona u skrivenom sloju iznad 13 ne ukazuje na značajan pad vrednosti srednje kvadratne greške, niti značajan rast vrednosti koeficijenta determinacije (prema slikama 6.2.5. i 6.2.6.). S toga je u skladu sa pravilom jednostavnije arhitekture mreže usvojen optimalan broj od 13 neurona u skrivenom sloju. Za 13 neurona u skrivenom sloju vrednost srednje kvadratne greške Levenberg–Marquardt-ovog algoritma sa sigmoidalnom logističkom funkcijom (*trainlm logsig*) iznosi $5,56 \cdot 10^{-5}$, dok koeficijent determinacije ima vrednost od 0,99904.



Slika 6.2.5. Varijacija vrednosti srednje kvadratne greške sa brojem neurona u skrivenom sloju mikrofiltracije kultivacione tečnosti *Bacillus velezensis* u uslovima recirkulacije napojne smeše u oba režima



Slika 6.2.6. Varijacija vrednosti koeficijenta determinacije sa brojem neurona u skrivenom sloju mikrofiltracije kultivacione tečnosti *Bacillus velezensis* u uslovima recirkulacije napojne smeše u oba režima

Kod modela neuronske mreže koji koristi algoritam Bayes-ove regularizacije sa hiperboličnom sigmoidalnom funkcijom (*trainbr tansig*) uočava se značajan rast srednje kvadratne greške za 10 neurona u skrivenom sloju, odnosno značajan pad vrednosti koeficijenta determinacije što ukazuje na moguć problem prekomernog treniranja. S toga je usvojeno 9 neurona za optimalan broj neurona u skrivenom sloju. Vrednosti srednje kvadratne greške i koeficijenta determinacije za 9 neurona u skrivenom sloju Bayes-ove regularizacije sa hiperboličnom sigmoidalnom funkcijom (*trainbr tansig*) iznose $1,13 \cdot 10^{-4}$ i 0,99808, respektivno. Za odabrani optimalan broj neurona u skrivenom sloju kod ovog modela neuronske mreže uočavaju se znatno veće vrednosti srednje kvadratne greške (slika 6.1.5.) i nešto manje vrednosti koeficijenta determinacije (slika 6.1.6.) u odnosu na vrednosti dobijene Levenberg–Marquardt-ovim algoritmom, što ukazuje na lošiju moć predviđanja.

U slučaju modela Bayes-ove regularizacije sa logističkom sigmoidalnom funkcijom (*trainbr logsig*) uočava se blagi pad vrednosti srednje kvadratne greške, odnosno blagi rast koeficijenta determinacije sa povećanjem broja neurona u skrivenom sloju iznad 13. S toga je optimalan broj neurona u skrivenom sloju određen na 13 prema pravilu jednostavnije strukture mreže. Za 13 neurona u skrivenom sloju vrednost srednje kvadratne greške iznosi $5,46 \cdot 10^{-5}$, dok je vrednost koeficijenta determinacije 0,99906. Kod ovog modela uočava se da

su vrednosti srednje kvadratne greške manje nego kod modela sa Levenberg–Marquardt-ovim algoritmom i logističkom sigmoidalnom prenosnom funkcijom (*trainlm logsig*), ali su takođe veće u odnosu na Levenberg–Marquardt-ov algoritam sa hiperboličnom sigmoidalnom prenosnom funkcijom (*trainlm tansig*).

Da bi se zadržala visoka predikcija optimalan broj neurona za aproksimaciju eksperimentalnih rezultata oba režima mikrofiltracije kultivacionih tečnosti na bazi mikroorganizama *Bacillus velezensis* u uslovima recirkulacije napojne smeše iznosi 13. Prema tome, optimalna arhitektura neuronske mreže je odabrana kao 3-13-1 sa hiperboličnom funkcijom prenosa i algoritmom treniranja Levenberg-Marquardt (*trainlm tansig*).

6.2.1. Validacija i verifikacija modela neuronske mreže u uslovima recirkulacije napojne smeše


Kao i u slučaju mikrofiltracije u uslovima koncentrisanja napojne smeše izvršeno je ispitivanje sposobnosti generalizacije optimalnog modela neuronske mreže, odnosno mogućnosti neuronske mreže da na osnovu zadatih ulaznih parametara pouzdano predvidi fluks permeata procesa mikrofiltracije u uslovima recirkulacije napojne smeše. Težinski koeficijenti i koeficijenti praga utvrđeni tokom obuke su sačuvani, mreža je ponovo pokrenuta sa novim podacima, a zatim je linearnom regresionom analizom izvršena ocena performansi modela.

Kao mera performansi razmatrana je tačnost predikcije modela neuronske mreže preko korelacije između normalizovanih eksperimentalno dobijenih vrednosti fluksa permeata i normalizovanih vrednosti dobijenih modelom na skupu podataka u režimu bez i sa statičkim promotorom turbulencije pošto su obučene mreže pokazale bolje rezultate sa manje neurona u skrivenom sloju. Mera tačnosti predikcije modela neuronske mreže procenjena je preko Pearson-ovog koeficijenta korelacije i koeficijenta determinacije.

Vrednosti Pearson-ovog korelacionog koeficijenta za normalizovane podatke promene fluksa sa vremenom tokom mikrofiltracije u uslovima recirkulacije napojne smeše iznose 0,99934 za režim bez statičkog promotora i 0,99841 za režim sa statičkim promotorom turbulencije. Visoke vrednosti Pearson-ovog korelacionog koeficijenta ukazuju na veoma dobru linearnu korelaciju između eksperimentalnih podataka i podataka predviđenih neuronskom mrežom što se može potvrditi dijagramom na slici 6.2.7.

Na osnovu rasporeda tačaka na dijagramu stvarnih i predviđenih vrednosti fluksa permeata (slika 6.2.7) uočava se nešto bolje fitovanje modela u režimu bez statičkog promotora turbulencije što znači da formirani model neuronske mreže bolje prati promene realnih vrednosti fluksa permeata tokom vremena u odnosu na režim sa statičkim promotorom tubulencije.

Vrednosti koeficijenta determinacije iznose 0,99868 i 0,99683 za normalizovane podatke promene fluksa tokom vremena u prisustvu statičkog promotora turbulencije i bez promotora tubulencije, respektivno. Visoke vrednosti koeficijenta determinacije ukazuju na veoma dobru pouzdanost predviđanja sa više od 99% podataka najbližih liniji najboljeg fitovanja (puna linija na slici 6.2.7. predstavlja idealno fitovanje linarnim modelom) u oba režima mikrofiltracije.



Slika 6.2.7. Dijagram linearne regresije mikrofiltracije kultivacione tečnosti *Bacillus velezensis* u uslovima recirkulacije napojne smeše za: a) režim bez statičkog promotora turbulencije, b) režim sa statičkim promotorom turbulencije

Na osnovu analize raspodele apsolutne relativne greške (tabela 6.2.1.) za oba režima (bez i sa statičkim promotorom turbulencije) model neuronske mreže je bio u stanju predvideti 94% podataka sa greškom manjom od 10%. U režimu bez statičkog promotora


turbulencije 5 podataka (2%) je predviđeno sa greškom većom od 20%, dok je za režim sa statičkim promotorom sa greškom većom od 20% predviđeno samo 3 podataka (1%). Podaci predviđeni sa većom greškom uglavnom su podaci koji se odnose na sam kraj eksperimentalnog postupka mikrofiltracije kada su promene relativne vrednosti fluksa permeata male, pa je i apsolutna relativna vrednost dobijenih grešaka veća. Nešto lošiji rezultati predviđanja neuronske mreže u SM režimu verovatno su posledica bržeg dostizanja stacionarnog stanja fluksa permeata u sistemu sa statičkim promotorom turbulencije kako se može videti na slici 6.2.8.

Tabela 6.2.1. Distribucija apsolutne relativne greške u uslovima recirkulacije napojne smeše

Apsolutna relativna greška (%)		<1	<5	<10	<20	>20	suma
NSM režim	Broj podataka	78	104	24	9	5	220
	%	35	48	11	4	2	100
SM režim	Broj podataka	99	101	24	12	3	239
	%	42	42	10	5	1	100

Već u početnoj fazi mikrofiltracije dolazi do precipitacije ćelija mikroorganizama na površinu membrane uzrokujući povećanje specifičnog otpora proticanju permeata i smanjenje fluksa permeata. Postavljanje promotora turbulencije unutar kanala membrane uzrokuje turbulentni režim proticanja koji narušavajući strukturu filtracione pogače smanjuje otpor proticanju permeata, što rezultuje većim fluksom, a samim tim i manjim padom fluksa permeata sa vremenom u poređenju sa sistemima bez mešača.

Za potvrdu kapaciteta generalizacije modela neuronske mreže, eksperimentalni podaci koji nisu bili uključeni u skupove podataka koji se koriste za obuku, validaciju i testiranje predstavljeni su obučenoj neuronskoj mreži. Eksperimenti su izvršeni za oba režima mikrofiltracije pri transmembranskom pritisku od 0,6 bara i protoku napojne smeše 60 L/h, a zatim su predstavljeni neuronskoj mreži. Na slici 6.2.8. se može videti da usvojena arhitektura neuronske mreže potpuno predviđa ponašanje fluksa permeata tokom mikrofiltracije fermentacione tečnosti mikroorganizma *Bacillus velezensis* u uslovima recirkulacije napojne smeše za oba režima mikrofiltracije pošto se vrednosti predviđenog fluksa permeata tačno poklapaju sa rezultatima koji su dobijeni eksperimentom.



Slika 6.2.8. Verifikacija modela neuronske mreže za denormalizovane vrednosti fuksa permeata mikrofiltracije kultivacione tečnosti *Bacillus velezensis* u uslovima recirkulacije napojne smeše : a) u režimu sa statičkim promotorom turbulencije, b) u režimu bez statičkog promotora turbulencije (Prilog 2, tabela P2.7)

6.2.2. Relativni značaj ulaznih promenljivih u uslovima recirkulacije napojne smeše

Relativni doprinos uticaja ulaznih promenljivih (vreme mikrofiltracije, protok napojne smeše i transmembranski pritisak) na fluks permeata u režimu bez i režimu sa statičkim promotorom turbulencije prilikom mikrofiltracije kultivacione tečnosti proizvodnog mikroorganizma *Bacillus velezensis* izračunati pomoću Garson-ove jednačine (6.1.) prikazani su u tabeli 6.2.2. Iz prikazanih rezultata može se videti da vreme filtracije ima najvažniju ulogu u određivanju pada fluksa permeata kod oba režima mikrofiltracije (oko 84% u režimu bez statičkog promotora turbulencije i oko 65% u režimu sa statičkim promotorom turbulencije). Ovakvi rezultati su u korelaciji sa rezultatima dobijenim za mikrofiltraciju u uslovima ugušćivanja. Interesantno je naglasiti da je uticaj vremena trajanja mikrofiltracije izraženiji kod sistema bez statičkog promotora turbulencije. Naime, tokom procesa na površini membrane dolazi do stalnog formiranja sloja pogače sastavljenog iz ćelija

mikroorganizama i finih čestica mutnoće za koje je membrana impermeabilna. Debljina ovog sloja se menja sa vremenom usled nagomilavanja čestica pod dejstvom razlike pritisaka zbog čega otpor proticanju stalno raste, a fluks opada. Unutar kanala membrane usled režima proticanja dolazi i do stalnog odnošenja jednog dela sloja pogače. U trenutku kada je brzina odnošenja komponenti sa sloja pogače jednaka brzini nanošenja novih komponenti na sloj dolazi do nastupanja tzv. pseudo stacionarnog stanja u kom je opadanje fluksa permeata sa vremenom manje izraženo. Postavljanjem statičkog mešača unutar kanala membrane usled promena u režimu proticanja dolazi do bržeg nastupanja stacionarnog stanja u odnosu na sistem bez statičkog promotora. pa je i uticaj vremena mikrofiltracije manje izražen.

Tabela 6.2.2. Relativni značaj ulaznih promenljivih mikrofiltracije u uslovima recirkulacije napojne smeše

Ulazni podaci	NSM režim		SM režim	
	Stepen značajnosti (%)	Rang	Stepen značajnosti (%)	Rang
Transmembranski pritisak	12.21	2	21.69	2
Protok napojne smeše	4.46	3	13.82	3
Vreme mikrofiltracije	83.33	1	64.49	1
UKUPNO:	100		100	

Sledeći faktor po važnosti je transmembranski pritisak, čiji se doprinos za oko 44% povećava ukoliko se statički promotor turbulencije postavi u membranski kanal. Razlog ovakvog ponašanja se može objasniti time da promena načina toka napojne smeše uzrokovana geometrijom statičkog promotora turbulencije utiče na promenu strukture i smanjeno nakupljanje filtracione pogače, pa je time i efekat transmembranskog pritiska u ovim sistemima izraženiji. Uticaj transmembranskog pritiska zavisi i od kompresibilnosti formirane pogače (Mota i sar., 2002, Jokić i sar., 2010). Uspostavljanje kompaktnije strukture filtracione pogače usled specifičnog rasporeda horizontalnog slaganja štapićastih oblika ćelija karakteristično je za mikroorganizame soja *Bacillus valezensis* (Mota i sar., 2002, Ben Hassan i sar., 2013, Hwang i Ku, 2014). Karakteristična struktura filtracione pogače usled tortuoznosti zbog nasumične prostorne organizacije ćelija i sile smicanja ispoljava veći otpor proticanju permeata u sistemima sa statičkim promotorom turbulencije, a samim tim je i porast uticaja transmembranskog pritiska veći (Ben Hassan i sar., 2013). U isto vreme, na raspored ćelija na površini membrane, formiranje poroznije strukture filtracione pogače utiču

i promene u obrascu protoka napojne smeše kroz membranski kanal koje su za 68% veće za sistem sa statičkim promotorom. Ovakvi rezultati su očekivani jer se sa porastom brzine proticanja usled promene obrasca protoka kroz membranski kanal uslovljene postavljanjem statičkog promotora utiče na odnošenje određene količine ćelija proizvodnog mikroorganizma sa površine pogače omogućujući veće vrednosti fluksa. Pojačan uticaj protoka napojne suspenzije usled postavljanja statičkog promotora turbulencije potvrđen je istraživanjima primene metode odzivne površine za modelovanje mikrofiltracije (Jokić i sar., 2010, Šereš i sar., 2018, Pajčin, 2019), a i tokom modelovanja mikrofiltracije kultivacione tečnosti *Streptomyces hygroscopicus* u uslovima ugušćivanja .

6.3. Modelovanje mikrofiltracije u uslovima dvofaznog toka

Kao i kod prethodnih ispitivanja primene neuronskih mreža za modelovanje mikrofiltracije (u uslovima koncentrisanja i u uslovima recirkulacije napojne smeše) i u slučaju mikrofiltracije sa dvofaznim tokom za obradu podataka odabran je model neuronske mreže sa 1 skrivenim slojem neurona. Pronalaženje optimalne arhitekture neuronske mreže kojom se postižu najbolje predikcione performanse izvršeno je simulacijom 10 modela neuronskih mreža formiranih kombinacijom pet algoritama obuke (*trainlm*, *trainbr*, *trainrp*, *trainscg* i *trainoss*) i dva tipa prenosne funkcije (*tansig* i *logsig*) između ulaznog i skrivenog sloja i linearne aktivacione funkcije između skrivenog i izlaznog sloja (tabela 5.2.1). Neuroni u ulaznom sloju određeni su na osnovu broja parametara variranih tokom eksperimenta mikrofiltracije (tabela 5.1.3), a fluks permeata koji se kao funkcija ulaznih promenljivih predviđa određen je kao izlazni neuron.

Eksperimentalni podaci mikrofiltracije uz uduvavanje vazduha su pre obučavanja normalizovani primenom jednačine 5.5., a zatim su nasumično podeljeni u tri grupe: 70% za trening, 15% za verifikaciju i 15% za testiranje kako je navedeno u poglavlju 5.2 (tabela 5.2.2). Kriterijumi prekidanja obučavanja mreže istovetni su kriterijumima primenjenim za slučaj ugušćivanja i recirkulaciju napojne smeše. Maksimalni broj epoha je postavljen na 1500, minimalna srednja kvadratna greška na 0, a najmanji gradijent učinka na $1 \cdot 10^{-10}$. Počevši od minimalne strukture sa jednim neuronom postepenim povećavanjem broja neurona u skrivenom sloju ispitivani su postignuti rezultati minimalne srednje kvadratne greške i koeficijenta determinacije svih modela neuronske mreže (rezultati za režim dvofaznog toka prikazani su u Prilogu 3, tabele P3.1 i P3.2). Gornja granica broja neurona u skrivenom sloju podešena je na 15 za sve ispitivane modele, a da bi se postigli najbolji rezultati mreže su pokrenute 30 puta.

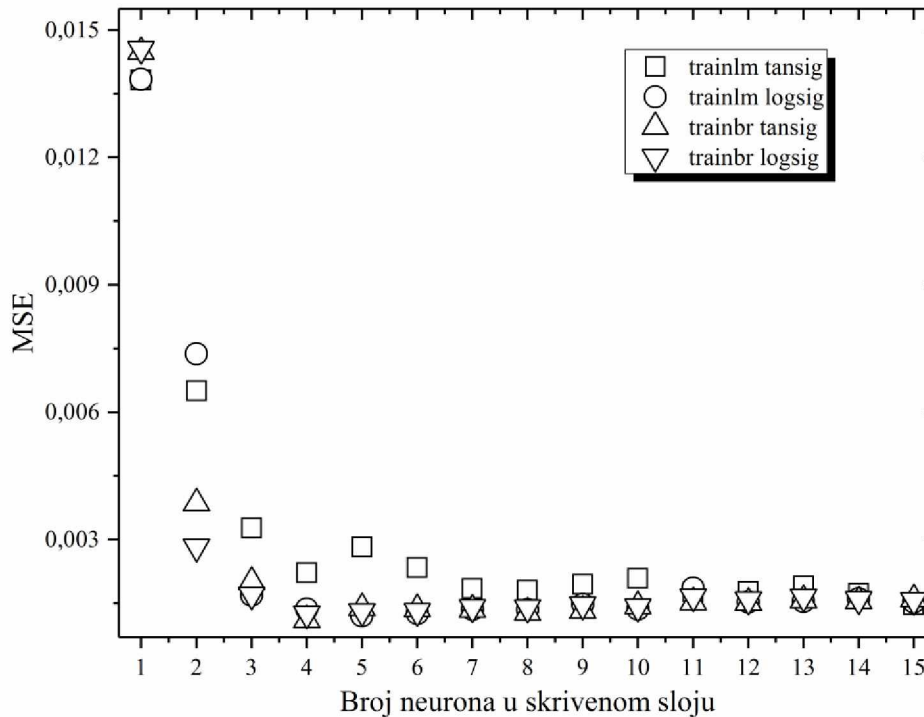
Posmatrajući srednju kvadratnu grešku podataka za proveru najveće vrednosti su postignute pri korišćenju algoritma rezilientnog povratnog prostiranja (*trainrp*), algoritma skaliranog konjugovanog gradijenta (*trainscg*) i algoritma jednostepenog sekantnog povratnog prostiranja greške unazad (*trainoss*). Naime, red veličine srednje kvadratne greške ovih modela ($1 \cdot 10^{-2}$) je 10 puta veći nego modela koji koristi Levenberg–Marquardt-ov algoritam obuke (*trainlm*) i modela algoritma sa Bayes-ovom regularizacijom (*trainbr*), tako da se može reći da modeli rezilientnog povratnog prostiranja, skaliranog konjugovanog gradijenta i jednostepenog sekantnog povratnog prostiranja greške unazad ne postižu dobre

predikcione sposobnosti. Prema tome su model sa Levenberg–Marquardt-ovim algoritmom i model sa algoritmom koji koristi Bayes-ovu regularizaciju odabrani za optimalne algoritme obučavanja neuronske mreže, pronalaženje optimalne arhitekture mreže i aproksimaciju eksperimentalnih rezultata.

Mreža sa minimalnim brojem neurona u skrivenom sloju koja daje maksimalni koeficijent determinacije i minimalnu srednju kvadratnu grešku je osnovni cilj optimalne topologije neuronske mreže. Prema slici 6.3.1. koja prikazuje varijaciju srednje kvadratne greške podataka za testiranje mreže za Levenberg–Marquardt-ov algoritam i algoritam Bayes-ove regularizacije može se videti da povećanje broja neurona u skrivenom sloju rezultuje boljom sposobnošću predviđanja pošto se srednja kvadratna greška približava ciljnoj graničnoj vrednosti postavljenoj za trening. Kada je dostignuto 5 neurona u skrivenom sloju u slučaju Levenberg–Marquardt-ovog algoritma sa sigmoidalnom hiperboličnom funkcijom (*trainlm tansig*) zapaža se blagi rast srednje kvadratne greške, međutim daljim povećanjem broja neurona dolazi do pada srednje kvadratne greške sve do 9 neurona u skrivenom sloju kada se ponovo uočava rast srednje kvadratne greške. Posmatrajući vrednost koeficijenta determinacije (slika 6.3.2.) u slučaju Levenberg–Marquardt-ovog algoritma sa sigmoidalnom hiperboličnom funkcijom (*trainlm tansig*) zapaža se pad ove vrednosti pri dostizanju 5 neurona u skrivenom sloju. Prema tome, može se zaključiti da za više od 4 neurona u skrivenom sloju model neuronske mreže pokazuje određenu nesposobnost generalizacije što može ukazati da je mreža naučila detalje u podacima za obuku, ali ne i ulazno-izlazne veze između promenljivih. S toga se može reći da povećanje broja neurona u skrivenom sloju ne doprinosi značajno poboljšanju predikcije mreže tako da se može usvojiti arhitektura mreže sa jednim skrivenim slojem u kom se nalazi 4 neurona. Za Levenberg–Marquardt-ov algoritam sa sigmoidalnom hiperboličnom funkcijom (*trainlm tansig*) sa 4 neurona u skrivenom sloju vrednosti srednje kvadratne greške i koeficijenta determinacije iznose $2,22 \cdot 10^{-3}$ i 0,99873, respektivno.


U slučaju korišćenja Levenberg–Marquardt-ovog algoritma sa sigmoidalnom logističkom funkcijom (*trainlm logsig*) uočava se blagi neznatni rast vrednosti srednje kvadratne greške od 5 do 9 neurona u skrivenom sloju kada vrednost srednje kvadratne greške počinje da opada (slika 6.3.1.). Vrednost koeficijenta determinacije raste sa povećanjem broja neurona u skrivenom sloju i dostiže maksimalnu vrednost sa 8 neurona (slika 6.3.2.). Daljim povećanjem broja neurona dolazi do manjeg pada vrednosti koeficijenta determinacije. Međutim, pri dostizanju 10 neurona u skrivenom sloju uočava se ponovni rast

koeficijenta determinacije, a nakon 11 neurona u skrivenom sloju ponovo dolazi do opadanja ove vrednosti. S toga je uzimajući u obzir pravilo jednostavnije arhitekture neuronske mreže usvojeno je 10 neurona za optimalan broj neurona u skrivenom sloju. Vrednosti srednje kvadratne greške i koeficijenta determinacije iznose $1,37 \cdot 10^{-3}$ i 0,98107, respektivno za 10 neurona u skrivenom sloju kod Levenberg–Marquardt-ovog algoritma sa sigmoidalnom logističkom funkcijom (*trainlm logsig*).



Slika 6.3.1. Varijacija vrednosti srednje kvadratne greške sa brojem neurona skrivenog sloja mikrofiltracije kultivacione smeše *Bacillus velezensis* u uslovima dvofaznog toka

Za model Bayes-ove regularizacije sa hiperboličnom sigmoidalnom funkcijom (*trainbp tansig*) minimalna vrednost srednje kvadratne greške postignuta je za 4 neurona u skrivenom sloju (slika 6.3.1.). Daljim povećanjem broja neurona u skrivenom sloju uočava se blagi rast vrednosti srednje kvadratne greške. Maksimalna vrednost koeficijenta determinacije postignuta je za 4 neurona u skrivenom sloju, a daljim povećanjem broja neurona u skrivenom sloju dolazi do blažeg pada vrednosti koeficijenta determinacije koji se nastavlja do 8 neurona u skrivenom sloju kada se vrednost ponovo povećava (slika 6.3.2.). Nakon 8 neurona u skrivenom sloju ponovo dolazi do pada vrednosti koeficijenta determinacije.



Slika 6.3.2. Varijacija vrednosti koeficijenta determinacije sa brojem neurona skrivenog sloja mikrofiltracije kultivacione smeše *Bacillus velezensis* u uslovima dvofaznog toka

S toga je za model Bayes-ove regularizacije sa hiperboličnom sigmoidalnom funkcijom (*trainbp tansig*) usvojen optimalan broj od 4 neurona u skrivenom sloju. Vrednosti srednje kvadratne greške i koeficijenta determinacije iznose $1,11 \cdot 10^{-3}$ i 0,98392, respektivno za 4 neurona u skrivenom sloju kod modela koji koristi Bayes-ovu regularizaciju sa hiperboličnom sigmoidalnom funkcijom (*trainbp tansig*). Isto ponašanje mreže uočava se i kod modela Bayes-ove regularizacije sa logističkom sigmoidalnom funkcijom (*trainbp logsig*). Kod modela koji koristi Bayes-ovu regularizaciju sa logističkom sigmoidalnom funkcijom (*trainbp tansig*) za 4 neurona u skrivenom sloju vrednosti srednje kvadratne greške i koeficijenta determinacije iznose $1,26 \cdot 10^{-3}$ i 0,98181, respektivno. Kod modela Bayes-ove regularizacije sa hiperboličnom sigmoidalnom funkcijom (*trainbp tansig*) uočavaju se manje vrednosti srednje kvadratne greške i veće vrednosti koeficijenta determinacije u odnosu na model Bayes-ove regularizacije sa logističkom sigmoidalnom prenosnom funkcijom (*trainbp logsig*), tako da ovaj model pokazuje bolju predikcionu sposobnost.

Na osnovu prethodnog može se zaključiti da optimalan broj neurona za aproksimaciju eksperimentalnih rezultata mikrofiltracije kultivacionih smeša na bazi mikroorganizama *Bacillus velezensis* u uslovima dvofaznog toka iznosi 10. Najbolje predikcione sposobnosti mreže pokazao je model neuronske mreže treniran algoritmom Lavenberg-Markuardt sa

logističkom sigmoidalnom prenosnom funkcijom (*trainlm logsig*) pošto je postigao najveće vrednosti koeficijenta determinacije, a odabrana optimalna arhitektura je 4-10-1.

6.3.1. Validacija i verifikacija modela neuronske mreže u uslovima dvofaznog toka

Sposobnost generalizacije modela neuronske mreže razmatrana je preko tačnosti modela da na osnovu zadatih ulaznih parametara pouzdano predvidi fluks permeata procesa mikrofiltracije u uslovima dvofaznog toka. Mera tačnosti predikcije modela neuronske mreže procenjena je preko Pearson-ovog koeficijenta korelacije i koeficijenta determinacije.

Visoka vrednost Pearson-ovog korelacionog koeficijenta od 0,99501 ukazuje na veoma dobru linearnu korelaciju između eksperimentalnih podataka i podataka predviđenih neuronskom mrežom što se može potvrditi dijagramom na slici 6.3.3. Na osnovu rasporeda tačaka na dijagramu stvarnih i predviđenih vrednosti fluksa permeata uočava se veoma dobro fitovanje modela što znači da razvijeni model neuronske mreže može adekvatno pratiti promene realnih vrednosti fluksa permeata tokom vremena.


Vrednost koeficijenta determinacije od 0,99002 za normalizovane podatke promene fluksa tokom vremena u uslovima dvofaznog toka ukazuje da linearna regresiona jednačina ne može da objasni manje od 1% varijacija u sistemu. Drugim rečima, 99% podataka je najbliže liniji najboljeg fitovanja (puna linija na slici 6.3.3. koja predstavlja idealno fitovanje linarnim modelom) što pokazuje veoma dobru pouzdanost predviđanja modela neuronske mreže.

Analizom raspodele apsolutne relativne greške detaljnije je izvršena procena predviđanja fluksa permeata modelom neuronske mreže. Prema tabeli 6.3.1. model neuronske mreže je bio u stanju predvideti 88% podataka sa greškom manjom od 10%, a samo 4% podataka ima apsolutnu relativnu grešku veću od 20%.

Tabela 6.3.1. Distribucija apsolutne relativne greške u uslovima dvofaznog toka


Apsolutna relativna greška (%)		<1	<5	<10	<20	>20	suma
Dvofazni tok	Broj podataka	64	117	40	17	10	248
	%	25	47	16	7	4	100

Nešto lošiji rezultati predviđanja neuronske mreže fluksa permeata u uslovima dvofaznog toka u odnosu na rezultate dobijene za mikrofiltraciju u uslovima recirkulacije napojne smeše mogu da se objasne veoma brzim uspostavljanjem stacionarnog stanja koji je posledica nestabilnog proticanja izazvanog uduvavanjem vazduha, kao i uticaja veličine mehurova vazduha i režima proticanja dvofaznog toka (slika 6.3.4).



Slika 6.3.3. Dijagram linearne regresije mikrofibracije kultivacione smeše *Bacillus velezensis* u uslovima dvofaznog toka

Kako bi se potvrdio generalizacijski kapacitet modela neuronske mreže, eksperimentalni podaci koji nisu bili uključeni u skupove podataka za obuku, validaciju i testiranje predstavljeni su obučenoj neuronskoj mreži. Eksperimenti mikrofibracije su izvršeni za transmembranski pritisak od 0,2 bar, prividnu brzinu napojne suspenzije od 0,43 m/s i prividnu brzinu vazduha od 0,2 m/s, a zatim su predstavljeni neuronskoj mreži. Na slici 6.3.8. se može videti da usvojena arhitektura neuronske mreže na zadovoljavajući način predviđa ponašanje fluksa permeata tokom mikrofibracije fermentacione tečnosti mikroorganizma *Bacillus velezensis* u uslovima dvofaznog toka, pošto se vrednosti predviđenog fluksa permeata poklapaju sa rezultatima koji su dobijeni eksperimentom.



Slika 6.3.4. Verifikacija modela neuronske mreže za denormalizovane vrednosti fluksa permeata u uslovima dvofaznog toka (Prilog 3, tabela P3.3)

Poređenjem sa rezultatima dobijenim za mikrofiltraciju u uslovima recirkulacije napojne suspenzije uočavaju se manje vrednosti fluksa permeata na samom početku mikrofiltracije u uslovima dvofaznog toka (oko $95 \text{ Lm}^{-2}\text{h}^{-1}$ u uslovima dvofaznog toka, oko $172 \text{ Lm}^{-2}\text{h}^{-1}$ u uslovima recirkulacije bez promotora turbulencije i oko $161 \text{ Lm}^{-2}\text{h}^{-1}$ u uslovima recirkulacije sa promotorom turbulencije).

Manje vrednosti fluksa permeata mikrofiltracije u uslovima dvofaznog toka na početku procesa mogu da se objasne otporom proticanju napojne smeše kroz kanale membrane koju stvaraju veliki mehurovi vazduha u čepovitom režimu ($\varepsilon = 0,32$) usled okupiranja jednog dela pora smanjujući efektivnu površinu membrane, kao i otporom proticanju usled formiranja kompaktnije filtracione pogače. Naime, usled dejstva sile smicanja dolazi do specifične prostorne organizacije ćelija mikroorganizama soja *Bacillus valezensis* u strukturi filtracione pogače koja zbog paralelne orijentacije ćelija mikroorganizama u odnosu na tok napojne smeše rezultuje kompaktnijom filtracionom pogačom (Hwang i Ku, 2014, Ben Hasan i sar., 2013, Pajčin, 2019).

Povećanje napona smicanja oko velikih mehurova vazduha u tečnosti utiče na narušavanje sloja koncentracione polarizacije čime se poboljšava prenos mase kroz membranu. Međutim, sa druge strane dolazi do povećanog adsorbovanja mikroorganizama i drugih čestica na površini membrane, uzrokujući sužavanje kanala membrane i smanjenja fluksa permeata. Čepovito proticanje kroz sužene kanale utiče na povećanje napona smicanja oko velikih mehurova vazduha u tečnosti, kao i pucanja koalescentih i velikih mehurova vazduha prilikom sudara sa formiranom pogačom i odvajanja njenih delova koji dovode do povećanja fluksa permeata (što se može zaključiti iz manjeg pada fluksa permeata sa

vremenom u uslovima dvofaznog toka u odnosu na fluks permeata ostvaren u uslovima recirkulacije napojne smeše bez promotora turbulencije (slika 6.2.8. i 6.3.3.)). Do sličnih zaključaka su došli Pospišil i sar. (2004) ispitujući uticaj dvofaznog toka na fluks permeata tokom mikrofiltracije vodenog rastvora titanijum dioksida kroz tubularnu aluminijumsku membranu. Znatan broj istraživača smatra da uduvavanje vazduha može povećati fluks permeata smanjujući reverzibilno prljanje membrane, međutim ne može uticati na ireverzibilno prljanje membrane (Youravong i sar., 2010, Hwang i Chen, 2010). Potvrda ove tvrdnje može se pronaći u boljim rezultatima vrednosti fluksa permeata u uslovima recirkulacije napojne smeše sa upotrebom promotora turbulencije u odnosu na vrednosti dobijene u uslovima dvofaznog toka. Ta tvrdnja se može objasniti uticajem geometrije statičkog promotora turbulencije na povećanu brzinu smicanja na površini membrane usled pojačavanja radijalnog mešanja i izazivanja lokalnih vrtloga u spiralama mešača koja zatim rezultuje smanjenim nakupljanjem filtracione pogače i uticajem biološkog prljanja membrane koje je karakteristično za guste suspenzije kao što je kultivaciona tečnost. Takođe, značajan broj autora smatra da režim čepovitog proticanja velikih mehurova verovatno doprinosi kompaktnijoj strukturi pogače, a time i manjim vrednostima fluksa permeata (Youravong i sar., 2010, Hwang i Chen, 2010). Opravdanost zaključka da uduvavanje vazduha u tok napojne smeše verovatno dovodi do još većeg komprimovanja filtracione pogače utičući na manje vrednosti fluksa permeata može se potvrditi manjim postignutim vrednostim fluksa permeata u odnosu na vrednosti dobijene u uslovima recirkulacije napojne smeše bez promotora turbulencije. Slične zaključke su izveli Hwang i Hsu (2009) istraživanjima mikrofiltracije ćelija kvasca u uslovima dvofaznog toka.

6.3.2. Relativni značaj ulaznih promenljivih u uslovima dvofaznog toka

Relativni doprinos uticaja ulaznih promenljivih (vreme mikrofiltracije, transmembranski pritisak, prividna brzina napojne smeše i prividna brzina vazduha) na fluks permeata prilikom mikrofiltracije kultivacione tečnosti proizvodnog mikroorganizma *Bacillus velezensis* u uslovima dvofaznog toka izračunati pomoću Garson-ove jednačine (6.1.) prikazani su u tabeli 6.3.2.

Iz prikazanih rezultata može se videti da vreme filtracije ima najvažniju ulogu u određivanju pada fluksa permeata (oko 64%). Ovakvi rezultati su u korelaciji sa rezultatima

dobijenim za mikrofiltraciju u uslovima ugušćivanja i mikrofiltraciju u uslovima recirkulacije napojne suspenzije.

Tabela 6.3.2. Relativni značaj ulaznih promenljivih mikrofiltracije u uslovima dvofaznog toka

Ulazni podaci	Dvofazni tok	
	Stepen značajnosti (%)	Rang
Transmembranski pritisak	11,80	3
Prividna brzina vazduha	10,46	4
Prividna brzina tečnosti	14,24	2
Vreme mikrofiltracije	63,50	1
UKUPNO:	100	

Već u početnoj fazi mikrofiltracije dolazi do pada fluksa permeata zbog prljanja membrane usled adsorpcije i akumulacije mikroorganizama i makromolekula na površini membrane, ali i ćelijskih ostataka, drugih čestica i proteina, izlučevina mikroorganizama koji imaju tendenciju agregiranja i akumuliranja na zidove pora membrane izazivajući suženje pora membrane. Debljina sloja filtracione pogače se menja sa vremenom usled nagomilavanja čestica pod dejstvom razlike pritisaka zbog čega otpor proticanju stalno raste, a fluks permeata opada. Unutar kanala membrane usled režima proticanja dolazi i do stalnog odnošenja jednog dela sloja pogače. U trenutku kada je brzina odnošenja komponenti sa sloja pogače jednaka brzini nanošenja novih komponenti na sloj dolazi do nastupanja tzv. pseudo stacionarnog stanja, odnosno do ustaljivanja debljine filtracione pogače u kom dolazi do manjeg opadanja fluksa permeata sa vremenom.

Sledeći faktor po važnosti relativnog uticaja na fluks permeata je prividna brzina tečnosti sa udelom značajnosti od oko 14%. Na početku procesa dolazi do nasumičnog deponovanja ćelija mikroorganizama na površini membrane usled poprečnog strujanja toka permeata i uzdužnog strujanja toka napojne smeše tako da je struktura filtracione pogače manje uređena, pa su i vrednosti fluksa permeata veće. Uspostavljanje kompaktnije strukture filtracione pogače usled specifičnog rasporeda horizontalnog slaganja štapićastih oblika ćelija mikroorganizama soja *Bacillus velezensis* ispoljava veći otpor proticanju permeata uslovljavajući pad fluksa permeata (Mota i sar., 2002, Ben Hassan i sar., 2013, Hwang i Ku, 2014, Pajčin, 2019). Sa druge strane, povećanje brzine proticanja napojne smeše u kanalu

membrane utiče na promenu režima proticanja koja narušava strukturu filtracione pogače, a usled čega dolazi do smanjenog otpora proticanju permeata rezultujući većim fluksom. Turbulentno proticanje napojne smeše ima veći stepen značajnosti relativnog uticaja na fluks permeata u odnosu na prividnu brzinu vazduha, što znači da će povećanje prividne brzine napojne smeše rezultovati većim fluksom permeata i bez uduvavanja vazduha.

Relativni uticaj transmembranskog pritiska na fluks permeata je za nešto više od 2% manji od relativnog uticaja protoka napojne suspenzije tako da se može zaključiti da se fluks permeata može efikasno povećati samo povećanjem protoka napojne smeše. Transmembranski pritisak je glavna pogonska sila za proces mikrofiltracije, ali dovodi i do intenzivnog taloženja na površini membrane. Na početku procesa filtraciona pogača se formira nasumičnom prostornom organizacijom ćelija mikroorganizama pod uticajem tortuoznog proticanja permeata kroz filtracioni sloj. Odmicanjem procesa usled dejstva sile smicanja dolazi do specifične prostorne organizacije ćelija mikroorganizama soja *Bacillus valezensis* u strukturi filtracione pogače koja zbog paralelne orijentacije ćelija mikroorganizama u odnosu na dvofazni tok gas-tečnost rezultuje kompaktnijom filtracionom pogačom, a uduvavanje vazduha u tok napojne smeše samo doprinosi povećanoj kompresibilnosti filtracione pogače (Mota i sar., 2002, Ben Hasan i sar., 2013, Pajčin, 2019). Kompaktna sturktura formirane filtracione pogače ispoljava veći otpor proticanju permeata, pa i uticaj transmembranskog pritiska raste (Jokić i sar., 2010). Ovi rezultati su u korelaciji sa rezultatima optimizacije procesa unakrsne mikrofiltracije suspenzije *Chlorella sp.* u uslovima dvofaznog toka (Javadi i sar., 2014). Autori navode da je efekat uticaja prividne brzine tečnosti mnogo veći od uticaja transmembranskog pritiska usled toga što veći protok napojne tečnosti izaziva veću turbulenciju i sile smicanja što otežava taloženje mikroalgi na površini membrane. Takođe, povećanje transmembranskog pritiska ima dva suprotna efekta na fluks permeata: pozitivan efekat usled povećanja pogonske sile mikrofiltracije i negativan efekat koji rezultuje formiranjem kompaktnijeg sloja deponovanih ćelija i njihovih ekstracelularnih polimernih supstanci.

Najmanji uticaj na fluks permeata ima prividna brzina vazduha sa stepenom značajnosti od oko 10% koja se može objasniti sinergičnim delovanjem proticanja napojne smeše i uduvavanja vazduha i da bi režim proticanja imao veći uticaj na fluks permeata od same prividne brzine gasne faze. Iz dobijenog rezultata uticaja prividne brzine vazduha na fluks permeata stiče se utisak da uduvavanje vazduha ne može značajno da doprinese formiranju komprimovanije filtracione pogače koja će rezultovati većem otporu permeata, a ni većem

narušavanju strukture filtracione pogače . Povećanje prividne brzine vazduha utiče na izmenu režima proticanja dvofaznog toka gasa i tečnosti iz mehurastog režima u režim proticanja velikih mehura koji bi usled povećanja napona smicanja, kao i pucanja koalescentih i velikih mehurova gasa prilikom sudara sa formiranom pogačom trebali narušiti njenu strukturu omogućujući veće vrednosti fluksa permeata. Mogući razlog ovakvog rezultata je opadanje mase filtracione pogače sa vremenom do određene vrednosti kada dalje povećanje brzine proticanja gasa ne doprinosi njenom smanjenju. Do sličnih zaključaka su došli Hwang i sar. (2010) ispitujući mikrofiltraciju binarne suspenzije kvasca i albumina goveđeg seruma.

6.4. Modelovanje mikrofiltracije u uslovima kombinovane primene promotora turbulencije i dvofaznog toka

Kao i kod prethodnih ispitivanja u slučaju mikrofiltracije sa kombinovanim postupkom primene dvofaznog toka sa promotorom turbulencije za obradu podataka odabran je model neuronske mreže sa 1 skrivenim slojem neurona. Optimalna arhitektura neuronske mreže kojom se postižu najbolje predikcione performanse odabrana je simulacijom 10 modela neuronskih mreža formiranih kombinacijom pet algoritama obuke (*trainlm*, *trainbr*, *trainrp*, *trainscg* i *trainoss*) i dva tipa prenosne funkcije (*tansig* i *logsig*) između ulaznog i skrivenog sloja i linearne aktivacione funkcije između skrivenog i izlaznog sloja (tabela 5.2.1). Neuroni u ulaznom sloju određeni su na osnovu broja parametara variranih tokom eksperimenta mikrofiltracije (tabela 5.1.4), a fluks permeata koji se kao funkcija ulaznih promenljivih predviđa određen je kao izlazni neuron.

Eksperimentalni podaci mikrofiltracije uz uduvavanje vazduha su pre obučavanja normalizovani primenom jednačine 5.5., a zatim su randomizovani u tri grupe: 70% za trening, 15% za verifikaciju i 15% za testiranje kako je navedeno u poglavlju 5.2 (tabela 5.2.2.). Kriterijumi prekidanja obučavanja mreže istovetni su kriterijumima primenjenim za slučaj ugušćivanja, recirkulaciju napojne smeše i primenu dvofaznog toka. Maksimalni broj epoha je postavljen na 1500, minimalna srednja kvadratna greška na 0, a najmanji gradijent učinka na 10^{-10} . Postignuti rezultati minimalne srednje kvadratne greške podataka za proveru obuke svih odabranih modela neuronske mreže ispitivani su postepenim povećavanjem broja neurona u skrivenom sloju počevši od minimalne strukture neuronske mreže sa jednim neuronom i ispitivanjem postignutih rezultata, minimalne srednje kvadratne greške i koeficijenta determinacije (rezultati za kombinovanu primenu dvofaznog toka i promotora turbulencije prikazani su u Prilogu 4, tabele P4.1 i P4.2). Gornja granica broja neurona u skrivenom sloju podešena je na 15 za sve ispitivane modele, a da bi se postigli najbolji rezultati mreže su pokrenute 30 puta.


Prema rezultatima srednje kvadratne greške podataka za proveru najveće vrednosti su postignute pri korišćenju algoritma rezilientnog povratnog prostiranja (*trainrp*), algoritma skaliranog konjugovanog gradijenta (*trainscg*) i algoritma jednostepenog sekantnog povratnog prostiranja greške unazad (*trainoss*) (Prilog 4, tabela P4.1). Red veličine srednje kvadratne greške ovih modela od $1 \cdot 10^{-2}$ je 100 puta veći nego modela koji koristi Levenberg–Marquardt-ov algoritam obuke (*trainlm*) i modela sa Bayes-ovom regularizacijom (*trainbr*)

čiji je red veličine minimalne srednje kvadratne greške $1 \cdot 10^{-4}$. Kako je jedan od osnovnih zahteva optimalne topologije neuronska mreža koja daje minimalnu srednju kvadratnu grešku, smatra se da modeli rezilientnog povratnog prostiranja, skaliranog konjugovanog gradijenta i jednostepenog sekantnog povratnog prostiranja greške unazad neće postići dobre predikcione sposobnosti. S toga su model sa Levenberg–Marquardt-ovim algoritmom i model sa algoritmom koji koristi Bayes-ovu regularizaciju odabrani za optimalne algoritme obučavanja neuronske mreže, pronalaženje optimalne arhitekture mreže i aproksimaciju eksperimentalnih rezultata.

Prema slici 6.4.1. može se videti da povećanje broja neurona u skrivenom sloju rezultuje boljom sposobnošću predviđanja pošto se srednja kvadratna greška približava ciljnoj graničnoj vrednosti postavljenoj za trening. Kada je dostignuto 11 neurona u skrivenom sloju u slučaju Levenberg–Marquardt-ovog algoritma sa sigmoidalnom hiperboličnom funkcijom (*trainlm tansig*) zapaža se blaži rast srednje kvadratne greške, međutim daljim povećanjem broja neurona dolazi do opadanja srednje kvadratne greške. Posmatrajući vrednost koeficijenta determinacije (slika 6.4.2.) u slučaju Levenberg–Marquardt-ovog algoritma sa sigmoidalnom hiperboličnom funkcijom (*trainlm tansig*) zapaža se pad vrednosti pri dostizanju 8 neurona u skrivenom sloju. Daljim povećanjem broja neurona vrednost koeficijenta determinacije raste sve do 11 neurona u skrivenom sloju kada ponovo opada. S toga se može reći da povećanje broja neurona u skrivenom sloju ne doprinosi značajno poboljšanju predikcije mreže tako da se može usvojiti arhitektura mreže sa jednim skrivenim slojem u kom se nalazi 7 neurona. Za Levenberg–Marquardt-ov algoritam sa sigmoidalnom hiperboličnom funkcijom (*trainlm tansig*) sa 7 neurona u skrivenom sloju vrednosti srednje kvadratne greške i koeficijenta determinacije iznose $9,01 \cdot 10^{-4}$ i 0,98713, respektivno.

U slučaju korišćenja Levenberg–Marquardt-ovog algoritma sa sigmoidalnom logističkom funkcijom (*trainlm logsig*) takođe se uočava blagi neznatni rast vrednosti srednje kvadratne greške sa 11 neurona u skrivenom sloju (slika 6.4.1.). Vrednost koeficijenta determinacije raste sa povećanjem broja neurona u skrivenom sloju do 11 neurona kada se uočava blaži neznatni pad. Daljim povećanjem neurona u skrivenom sloju uočava se ponovni rast koeficijenta determinacije koji dostiže maksimalnu vrednost sa 14 neurona u skrivenom sloju (slika 6.4.2.). Uzimajući u obzir pravilo jednostavnije arhitekture neuronske mreže usvojeno je 10 neurona za optimalan broj neurona u skrivenom sloju. Vrednosti srednje kvadratne greške i koeficijenta determinacije iznose $5,30 \cdot 10^{-4}$ i 0,99285, respektivno za 10

neurona u skrivenom sloju kod Levenberg–Marquardt-ovog algoritma sa sigmoidalnom logističkom funkcijom (*trainlm logsig*).




Slika 6.4. 1. Varijacija vrednosti srednje kvadratne greške sa brojem neurona skrivenog sloja mikrofiltracije kultivacione smeše *Bacillus velezensis* u uslovima kombinovanog postupka

Za model Bayes-ove regularizacije sa hiperboličnom sigmoidalnom funkcijom (*trainbp tansig*) uočava se rast vrednosti srednje kvadratne greške sa 10 neurona u skrivenom sloju (slika 6.4.1.). Daljim povećanjem broja neurona u skrivenom sloju uočava se blagi pad vrednosti srednje kvadratne greške do 13 neurona u skrivenom sloju kada se uočava ponovni rast ove vrednosti. Vrednost koeficijenta determinacije raste do 3 neurona u skrivenom sloju kada se uočava blagi pad ove vrednosti, a daljim povećanjem broja neurona u skrivenom sloju uočava se povremeni rast, odnosno pad vrednosti koeficijenta determinacije. S toga se može zaključiti da model neuronske mreže pokazuje određenu nesposobnost generalizacije što može ukazati da je mreža naučila detalje u podacima za obuku, ali ne i ulazno-izlazne veze između promenljivih.

Vrednost srednje kvadratne greške kod modela koji koristi Bayes-ovu regularizaciju sa logističkom sigmoidalnom funkcijom (*trainbp tansig*) opada sa povećanjem broja neurona u skrivenom sloju do dostizanja 10 neurona kada se uočava blagi rast ove vrednosti. Daljim povećanjem neurona u skrivenom sloju ponovo dolazi do pada srednje kvadratne greške. Isto

ponašanje se uočava i kod vrednosti koeficijenta determinacije, pa se može reći da povećanje broja neurona iznad 9 ne doprinosi značajno poboljšanju predikcije mreže i usvojiti arhitektura mreže sa jednim skrivenim slojem u kom se nalazi 9 neurona. Vrednosti srednje kvadratne greške i koeficijenta determinacije iznose $5,98 \cdot 10^{-4}$ i 0,99181, respektivno za 9 neurona u skrivenom sloju kod modela koji koristi Bayes-ovu regularizaciju sa logističkom sigmoidalnom funkcijom (*trainbp tansig*).



Slika 6.4. 2. Varijacija vrednosti koeficijenta determinacije sa brojem neurona skrivenog sloja mikrofiltracije kultivacione smeše *Bacillus velezensis* u uslovima kombinovanog postupka

Na osnovu prethodnog može se zaključiti da optimalan broj neurona za aproksimaciju eksperimentalnih rezultata mikrofiltracije kultivacionih smeša na bazi mikroorganizama *Bacillus velezensis* u uslovima dvofaznog toka iznosi 10. Najbolje predikcione sposobnosti mreže pokazao je model neuronske mreže treniran algoritmom Lavenberg-Markuardt sa logističkom sigmoidalnom prenosnom funkcijom (*trainlm logsig*) pošto je postigao najveće vrednosti koeficijenta determinacije, a optimalna arhitektura je odabrana kao 4-10-1.

6.4.1. Validacija i verifikacija modela neuronske mreže uz primenu promotora turbulencije i dvofaznog toka

Mera tačnosti predikcije modela neuronske mreže da na osnovu zadatih ulaznih parametara pouzdano predvidi fluks permeata procesa mikrofiltracije u uslovima kombinovane promene dvofaznog toka i promotora turbulencije procenjena je preko Pearson-ovog koeficijenta korelacije i koeficijenta determinacije.


Vrednost Pearson-ovog korelacionog koeficijenta od 0,99744 ukazuje na veoma dobru linearnu korelaciju između eksperimentalnih podataka i podataka predviđenih neuronskom mrežom, što se može potvrditi dijagramom na slici 6.4.3. Raspored tačaka na slici 6.4.3. pokazuje na veoma dobro podudaranje normalizovanih eksperimentalno dobijenih vrednosti fluksa permeata i normalizovanih vrednosti koje su predviđene neuronskom mrežom što znači da formirani model neuronske mreže može sa visokom tačnošću predvideti promene realnih vrednosti fluksa permeata tokom vremena.

Visoka vrednost koeficijenta determinacije od 0,99489 sugeriše na veoma dobru aproksimaciju eksperimentalnih rezultata procesa mikrofiltracije u uslovima kombinovane primene dvofaznog toka i promotora turbulencije formiranim modelom neuronske mreže. Dobijena vrednost koeficijenta determinacije od 0,99489 ukazuje da linearna regresiona jednačina modela za fluks permeata ne može da objasni manje od 0,6% varijacija u sistemu (puna linija na slici 6.4.3. predstavlja idealno fitovanje linearnim modelom), što znači visoku pouzdanost predviđanja neuronske mreže.

Detaljnija procena predviđanja fluksa permeata unakrsne mikrofiltracije uz kombinovanu primenu dvofaznog toka i promotora turbulencije modelom neuronske mreže izvršena je analizom raspodele apsolutne relativne greške. Prema tabeli 6.4.1 model neuronske mreže je bio u stanju predvideti 86% podataka sa greškom manjom od 10%. Pri tom za 75% podataka vrednost apsolutne relativne greške manja je od 5%, a samo 6% podataka ima apsolutnu relativnu grešku veću od 20%.

Interesanto je uočiti sličnu grešku predviđanja pada fluksa permeata u uslovima kombinovane primene dvofaznog toka i promotora turbulencije (tabela 6.4.1) sa rezultatima dobijenim za mikrofiltraciju u uslovima dvofaznog toka (tabela 6.3.1). Naime, vrednost apsolutne relativne greške predviđanja fluksa permeata u uslovima kombinovane primene dvofaznog toka i promotora turbulencije manja je od 5% za 75% podataka, dok je kod mikrofiltracije u uslovima dvofaznog toka vrednost apsolutne relativne greške manja od 5%

za 72% podataka. Ovakvi rezultati mogu da se objasne veoma brzim dostizanjem stacionarnog stanja koji je posledica režima proticanja dvofaznog toka kao i turbulencije pojačane umetanjem promotora turbulencije u kanal membrane i dodatnim uduvavanjem vazduha u napojni tok kultivacione tečnosti (slika 6.4.4).




Slika 6.4.3. Dijagram linearne regresije mikrofiltracije kultivacione smeše *Bacillus velezensis* kombinovanom primenom dvofaznog toka i promotora turbulencije

Tabela 6.4.1. Distribucija apsolutne relativne greške u uslovima kombinovanog postupka

Apsolutna relativna greška (%)		<1	<5	<10	<20	>20	suma
Kombinovani postupak	Broj podataka	79	179	38	25	22	343
	%	23	52	11	7	6	100

Generalizacijski kapacitet modela obučene neuronske mreže potvrđen je predstavljanjem podataka koji nisu bili uključeni u skupove podataka za obuku, validaciju i testiranje. Eksperimenti mikrofiltracije su izvršeni za transmembranski pritisak od 0,2 bar,

prividnu brzinu napojne suspenzije 0,43 m/s i prividnu brzinu vazduha 0,2 m/s, a zatim su predstavljeni neuronskoj mreži.



Slika 6.4.4. Verifikacija modela neuronske mreže za denormalizovane vrednosti fluksa permeata u uslovima kombinovane primene dvofaznog toka i promotora turbulencije (Prilog 4, tabela P4.3)

Na slici 6.4.4. se može videti poklapanje vrednosti fluksa permeata predviđenih neuronskom mrežom i rezultata koji su dobijeni eksperimentalnim putem. Prema tome se može zaključiti da usvojena arhitektura neuronske mreže na zadovoljavajući način predviđa ponašanje fluksa permeata tokom mikrofiltracije fermentacione tečnosti mikroorganizma *Bacillus velezensis* u uslovima kombinovane primene dvofaznog toka i promotora turbulencije.

Poređenjem sa rezultatima dobijenim za mikrofiltraciju u uslovima dvofaznog toka u ovim eksperimentima uočavaju se veće vrednosti fluksa permeata na samom početku mikrofiltracije (oko 95 Lm⁻²h⁻¹ u uslovima dvofaznog toka, a oko 180 Lm⁻²h⁻¹ u uslovima kombinovane primene dvofaznog toka i promotora turbulencije). Primećuje se da su vrednosti fluksa permeata u uslovima kombinovane primene dvofaznog toka i promotora turbulencije veće i od vrednosti koje su dobijene za mikrofiltraciju u uslovima recirkulacije napojne smeše sa promotorom turbulencije (oko 161 Lm⁻²h⁻¹). Veće vrednosti fluksa permeata u uslovima kombinovane primene dvofaznog toka i promotora turbulencije mogu da se objasne jačom silom smicanja koju izaziva turbulencija izazvana tokom smeše tečnosti i vazduha i pojačanim radijalnim mešanjem i lokalnim vrtloženjima u spiralama helikoidnih elemenata promotora turbulencije. Smicanje koje vrši turbulento proticanje izazvano uduvavanjem vazduha u tok napojne smeše i uticaj promotora turbulencije sprečava deponovanje mikroorganizama i njihovih metabolita na površini membrane i olakšava

odnošenje već deponovanih čestica sa filtracione pogače stvarajući porozniju strukturu i omogućujući postizanje većih vrednosti fluksa permeata.

6.4.2. Relativni značaj ulaznih promenljivih mikrofiltracije u uslovima kombinovane primene promotora turbulencije i dvofaznog toka

Relativni doprinosi uticaja ulaznih promenljivih (vreme mikrofiltracije, transmembranski pritisak, prividna brzina napojne smeše i prividna brzina vazduha) na fluks permeata prilikom mikrofiltracije kultivacione tečnosti proizvodnog mikroorganizma *Bacillus velezensis* u uslovima kombinovane primene promotora turbulencije i dvofaznog toka izračunati pomoću Garson-ove jednačine (6.1.) prikazani su u tabeli 6.4.2. Iz prikazanih rezultata može se videti da vreme filtracije ima najvažniju ulogu u određivanju pada fluksa permeata (oko 55%). Ovakvi rezultati su u korelaciji sa rezultatima dobijenim za mikrofiltraciju u uslovima ugušćivanja, u uslovima recirkulacije napojne suspenzije i u uslovima primene uduvavanja vazduha.

Tabela 6.4.2. Relativni značaj ulaznih promenljivih mikrofiltracije u uslovima kombinovane primene promotora turbulencije i dvofaznog toka

Ulazni podaci	Kombinovani postupak	
	Stepen značajnosti (%)	Rang
Transmembranski pritisak	12,40	4
Prividna brzina vazduha	14,25	3
Prividna brzina tečnosti	18,37	2
Vreme mikrofiltracije	54,98	1
UKUPNO:	100	

Debljina sloja filtracione pogače se menja sa vremenom usled adsorpcije i akumulacije mikroorganizama i makromolekula na površini membrane, ali i ćelijskih ostataka, drugih čestica i proteina pod dejstvom razlike pritiska zbog čega otpor proticanju stalno raste, a fluks opada. Istovremeno unutar kanala membrane usled turbulentog režima proticanja izazvanog promotorom turbulencije i uduvavanjem vazduha dolazi i do stalnog odnošenja jednog dela sloja pogače. Ovaj fenomen je prisutan sve do uspostavljanja pseudo

stacionarnog stanja, kada je brzina odošenja komponenti sa sloja pogače jednaka brzini nanošenja novih komponenti, u kom dolazi do manjeg opadanja fluksa permeata sa vremenom.

Sledeći faktor po važnosti relativnog uticaja na fluks permeata je prividna brzina tečnosti sa udelom značajnosti od oko 18%. Brzina proticanja napojne smeše u kanalu membrane utiče na promenu režima proticanja koji narušavajući strukturu filtracione pogače rezultuje smanjenim otporom proticanju permeata i većim fluksom permeata (Cabassud i sar, 2001). U prethodnim poglavljima je zaključeno da struktura filtracione pogače koja se formira tokom mikrofiltracije kultivacione tečnosti *Bacillus valezensis* ima tendenciju komprimovanja usled specifične prostorne orijentacije karakterističnih oblika štapićastih mikroorganizama koja se dodatno povećava uduvavanjem vazduha. Na ovaj način se stvara veoma kompaktna struktura filtracione pogače koja pruža znatan otpor proticanju kroz membranske kanale utičući na pad fluksa permeata. Turbulencija izazvana umetanjem promotora u kanal membrane doprinosi značajnoj promeni režima proticanja dvofaznog toka izazivajući pucanje i koalescenciju velikih mehurova vazduha kao i omogućavanju da se proticanje manjih mehurova vazduha odvija bliže površini kanala membrane. Povećanje brzine kultivacione tečnosti će prema tome dovesti do potpunog narušavanja strukture filtracione pogače, čak i sprečavanja manjih komponenti kultivacione tečnosti da izazovu unutrašnje prljanje membrane. Značajno smanjenje otpora proticanju omogućiće veće vrednosti fluksa permeata. Ovom zaključku doprinosi i veći stepen značajnosti relativnog uticaja prividne brzine vazduha (od oko 14%) u odnosu na vrednost dobijenu u uslovima primene dvofaznog toka (nešto više od 10% prema tabeli 6.3.2). Stepem značajnosti relativnog uticaja prividne brzine napojne smeše veći je od relativnog uticaja prividne brzine vazduha za nešto više od 4% tako da se može zaključiti da se fluks permeata može efikasno povećati samo povećanjem protoka napojne smeše. Međutim, zajednički uticaj povećanja prividne brzine proticanja napojne smeše i prividne brzine vazduha pojačan dejstvom statičkog promotora turbulencije može dovesti do toga da se usled izuzetno turbulentnog režima proticanja debljina filtracione pogače toliko stanji omogućujući penetraciju komponenti manjih dimenzija u pore membrane. To će dovesti do pojačanog unutrašnjeg prljanja membrane i smanjenja vrednosti fluksa permeata. Do sličnih zaključaka došli su i Armbruster i sar. (2019) ispitujući prljanje membrane tokom mikrofiltracije rastvora soli huminske kiseline uz uduvavanje vazduha u prisustvu promotora turbulencije.

Najmanji uticaj na fluks permeata ima transmembranski pritisak koji se može objasniti time da uticaj transmembranskog pritiska u velikoj meri zavisi od kompresibilnosti filtracione pogače. Turbulentno proticanje dvofazne smeše tečnosti i vazduha kroz kanal membrane pojačano promotorom utiče na to da je struktura filtracione pogače manje uređena tako da će ispoljiti manji otpor proticanju permeata, pa je time i uticaj transmembranskog pritiska manji.

6.5. Modelovanje objedinjenih podataka mikrofiltracije kultivacione tečnosti *Bacillus velezensis*

Kako bi se dobila jedinstvena neuronska mreže za simulaciju svih metoda poboljšanja fluksa permeata tokom mikrofiltracije kultivacione tečnosti *Bacillus velezensis* analiza sposobnosti predviđanja, kao i u prethodnim poglavljima, izvršena je na modelu neuronske mreže sa 1 skrivenim slojem neurona i ukupnim eksperimentalnim rezultatima. Optimalna arhitektura neuronske mreže kojom se postižu najbolje predikcione performanse odabrana je simulacijom 10 modela neuronskih mreža formiranih kombinacijom pet algoritama obuke (*trainlm*, *trainbr*, *trainrp*, *trainscg* i *trainoss*) sa dva tipa prenosne funkcije (*tansig* i *logsig*) između ulaznog i skrivenog sloja i linearne aktivacione funkcije između skrivenog i izlaznog sloja (tabela 5.2.1). Neuroni u ulaznom sloju određeni su na osnovu broja parametara variranih tokom eksperimenta mikrofiltracije (tabele 5.1.2, 5.1.3 i 5.1.4), a kao izlazni neuron određen je fluks permeata koji se kao funkcija ulaznih promenljivih predviđa.

Objedinjeni eksperimentalni podaci mikrofiltracije su pre obučavanja normalizovani primenom jednačine 5.5., a zatim su randomizovani u tri grupe: 70% za trening, 15% za verifikaciju i 15% za testiranje kako je navedeno u poglavlju 5.2 (tabela 5.2.2.). Kriterijumi prekidanja obučavanja mreže istovetni su kriterijumima primenjenim u prethodnim poglavljima. Maksimalni broj epoha je postavljen na 1500, minimalna srednja kvadratna greška na 0, a najmanji gradijent učinka na $1 \cdot 10^{-10}$. Postignuti rezultati minimalne srednje kvadratne greške podataka za proveru obuke svih odabranih modela neuronske mreže ispitivani su postepenim povećavanjem broja neurona u skrivenom sloju počevši od minimalne strukture neuronske mreže sa jednim neuronom, a zatim je izvršeno i ispitivanje vrednosti koeficijenta determinacije (rezultati svih metoda poboljšanja fluksa permeata tokom mikrofiltracije kultivacione tečnosti *Bacillus velezensis* prikazani su u Prilogu 5, tabele P5.1 i P5.2). Gornja granica broja neurona u skrivenom sloju podešena je na 15 za sve ispitivane modele, a da bi se postigli najbolji rezultati mreže su pokrenute 30 puta.


Prema rezultatima srednje kvadratne greške podataka za proveru uočava se da modeli sa algoritmom rezilientnog povratnog prostiranja (*trainrp tansig* i *trainrp logsig*), modeli sa algoritmom skaliranog konjugovanog gradijenta (*trainscg logsig* i *trainscg i logsig*) i modeli sa algoritmom jednostepenog sekantnog prostiranja greške unazad (*trainoss tansig* i *trainoss logsig*) postižu veći red veličine srednje kvadratne greške (koji iznosi $1 \cdot 10^{-3}$) u odnosu na modele sa Levenberg–Marquardt-ovim algoritmom treninga i Bayes-ovom regularizacijom,

koji postižu red veličine srednje kvadratne greške od $1 \cdot 10^{-4}$. Kako je jedan od osnovnih zahteva optimalne topologije neuronska mreža koja daje minimalnu srednju kvadratnu grešku, smatra se da modeli rezilientnog povratnog prostiranja, skaliranog konjugovanog gradijenta i jednostepenog sekantnog povratnog prostiranja greške unazad neće postići dobre predikcione sposobnosti. Na osnovu toga se može zaključiti da model sa Levenberg–Marquardt-ovim algoritmom i model sa algoritmom koji koristi Bayes-ovu regularizaciju više konvergiraju postavljenoj ciljnoj vrednosti minimalne srednje kvadratne greške u odnosu na ostale modele, što ukazuje na bolju moć predviđanja. Prema tome, modeli neuronskih mreža obučeni ovim algoritmima odabrani su za optimalne algoritme obučavanja neuronske mreže, pronalaženje optimalne arhitekture mreže i aproksimaciju eksperimentalnih rezultata.

Prema slici 6.5.1. može se videti da u slučaju Levenberg–Marquardt-ovog algoritma sa sigmoidalnom hiperboličnom funkcijom (*trainlm tansig*) povećanje broja neurona u skrivenom sloju rezultuje boljom sposobnošću predviđanja pošto se srednja kvadratna greška približava ciljnoj graničnoj vrednosti postavljenoj za trening. Minimalna vrednost srednje kvadratne greške postignuta je sa 15 neurona u skrivenom sloju. Takođe, se zapaža i konstantan rast vrednosti koeficijenta determinacije u slučaju Levenberg–Marquardt-ovog algoritma sa sigmoidalnom hiperboličnom funkcijom (*trainlm tansig*) sa povećanjem broja neurona u skrivenom sloju (slika 6.5.2.). Posmatrajući vrednost minimalne srednje kvadratne greške i koeficijenta determinacije uočava se da Levenberg–Marquardt-ov algoritam sa sigmoidalnom hiperboličnom funkcijom (*trainlm tansig*) postiže najmanju vrednost srednje kvadratne greške za 13 neurona u skrivenom sloju, a i najveći koeficijent determinacije u odnosu na druge modele odabrane za detaljnu analizu. Može se reći da povećanje broja neurona u skrivenom sloju ne doprinosi značajno poboljšanju predikcije mreže tako da se može usvojiti arhitektura mreže sa jednim skrivenim slojem u kom se nalazi 13 neurona. Za Levenberg–Marquardt-ov algoritam sa sigmoidalnom hiperboličnom funkcijom (*trainlm tansig*) sa 13 neurona u skrivenom sloju vrednosti srednje kvadratne greške i koeficijenta determinacije iznose $2,69 \cdot 10^{-4}$ i 0,99498, respektivno.

U slučaju korišćenja Levenberg–Marquardt-ovog algoritma sa sigmoidalnom logističkom funkcijom (*trainlm logsig*) minimalna vrednost srednje kvadratne greške postignuta je sa 15 neurona u skrivenom sloju (slika 6.5.1.), a i maksimalna vrednost koeficijenta determinacije. (slika 6.5.2.). Vrednosti srednje kvadratne greške i koeficijenta determinacije iznose $2,60 \cdot 10^{-4}$ i 0,99539, respektivno za 15 neurona u skrivenom sloju kod


Levenberg–Marquardt-ovog algoritma sa sigmoidalnom logističkom funkcijom (*trainlm logsig*).



Slika 6.5.1. Varijacija vrednosti srednje kvadratne greške sa brojem neurona skrivenog sloja mikrofiltracije kultivacione smeše *Bacillus velezensis* u uslovima primene svih metoda poboljšanja fluksa permeata

Za model Bayes-ove regularizacije sa hiperboličnom sigmoidalnom funkcijom (*trainbp tansig*) takođe se uočava pad vrednosti srednje kvadratne greške sa povećanjem broja neurona u skrivenom sloju (slika 6.5.1.). Minimalna vrednost srednje kvadratne greške i maksimalna vrednost koeficijenta determinacije postignuta je sa 15 neurona u skrivenom sloju. S toga se može zaključiti da model neuronske mreže pokazuje dobru sposobnost generalizacije sa optimalno 15 neurona u skrivenom sloju. Vrednosti srednje kvadratne greške i koeficijenta determinacije iznose $2,74 \cdot 10^{-4}$ i 0,99513, respektivno za 15 neurona u skrivenom sloju kod modela koji koristi Bayes-ovu regularizaciju sa hiperboličnom sigmoidalnom funkcijom (*trainbp tansig*). Vrednost srednje kvadratne greške kod modela koji koristi Bayes-ovu regularizaciju sa logističkom sigmoidalnom funkcijom (*trainbp tansig*) opada sa povećanjem broja neurona u skrivenom sloju i svoju minimalnu vrednost postiže sa 14 neurona u skrivenom sloju. Isto ponašanje se uočava i kod vrednosti koeficijenta determinacije, pa se može usvojiti arhitektura mreže sa jednim skrivenim slojem u kom se nalazi 14 neurona. Vrednosti srednje kvadratne greške i koeficijenta determinacije iznose

$2,74 \cdot 10^{-4}$ i 0,99515, respektivno za 14 neurona u skrivenom sloju kod modela koji koristi Bayes-ovu regularizaciju sa logističkom sigmoidalnom funkcijom (*trainbp tansig*).




Slika 6.5.2. Varijacija vrednosti koeficijenta determinacije sa brojem neurona skrivenog sloja mikrofiltracije kultivacione smeše *Bacillus velezensis* u uslovima primene svih metoda poboljšanja fluksa permeata

Osnovni cilj optimalne arhitekture neuronske mreže je dobiti što jednostavniju mrežu, odnosno mrežu sa minimalnim brojem skrivenih neurona koja daje maksimalni koeficijent determinacije i minimalnu srednju kvadratnu grešku. Na osnovu toga može se zaključiti da optimalan broj neurona za aproksimaciju eksperimentalnih rezultata mikrofiltracije kultivacionih smeša na bazi mikroorganizama *Bacillus velezensis* svih metoda poboljšanja fluksa permeata (primena promotora turbulencije u uslovima recirkulacije napojne smeše, primena dvofaznog toka i primena kombinovanog postupka dvofaznog toka i promotora turbulencije) iznosi 13. Najbolje predikcione sposobnosti mreže pokazao je model neuronske mreže treniran algoritmom Lavenberg-Markuardt sa hiperboličnom sigmoidalnom prenosnom funkcijom (*trainlm tansig*) pošto je postigao najveće vrednosti koeficijenta determinacije, a odabrana optimalna arhitektura mreže je 4-13-1.

6.5.1. Validacija i verifikacija modela neuronske mreže objedinjenih podataka mikrofiltracije kultivacione tečnosti *Bacillus velezensis*

Pouzdanost predviđanja fluksa permeata na osnovu zadatih ulaznih parametara procesa mikrofiltracije u uslovima primene svih hidrodinamičkih metoda poboljšanja fluksa permeata ocenjuje se na osnovu tačnosti predikcije. Tačnost predikcije modela neuronske mreže procenjena je preko Pearson-ovog koeficijenta korelacije i koeficijenta determinacije. Vrednost Pearson-ovog korelacionog koeficijenta od 0,99611 sugerise na dobru linearnu korelaciju između eksperimentalnih podataka i podataka predviđenih neuronskom mrežom, što se može potvrditi dijagramom na slici 6.5.3.



Slika 6.5.3. Dijagram linearne regresije mikrofiltracije kultivacione tečnosti *Bacillus velezensis* u uslovima primene svih metoda poboljšanja fluksa permeata

Vrednost koeficijenta determinacije od 0,99224 ukazuje da linearna regresiona jednačina modela za fluks permeata ne može da objasni manje od 0,8% varijacija u sistemu. Drugim rečima, 99,23% podataka je najbliže liniji najboljeg fitovanja (puna linija na slici

6.5.3. koja predstavlja idealno fitovanje linarnim modelom) što pokazuje veoma dobru pouzdanost predviđanja modela neuronske mreže, odnosno zadovoljavajuću aproksimaciju eksperimentalnih rezultata. Raspored tačaka na slici 6.5.3. pokazuje na solidno podudaranje normalizovanih eksperimentalno dobijenih vrednosti fluksa permeata i normalizovanih vrednosti koje su predviđene neuronskom mrežom što znači da formirani model neuronske mreže može sa znatnom tačnošću predvideti promene realnih vrednosti fluksa permeata tokom vremena.

Detaljnija procena predviđanja fluksa permeata unakrsne mikrofiltracije *Bacillus velezensis* (koristeći sve ispitivane metode poboljšanja fluksa permeata) modelom neuronske mreže izvršena je analizom raspodele apsolutne relativne greške. Prema tabeli 6.5.1 model neuronske mreže je bio u stanju predvideti 85% podataka sa greškom manjom od 10%. Pri tom za 67% podataka vrednost apsolutne relativne greške manja je od 5%, a samo 6% podataka ima apsolutnu relativnu grešku veću od 20%.

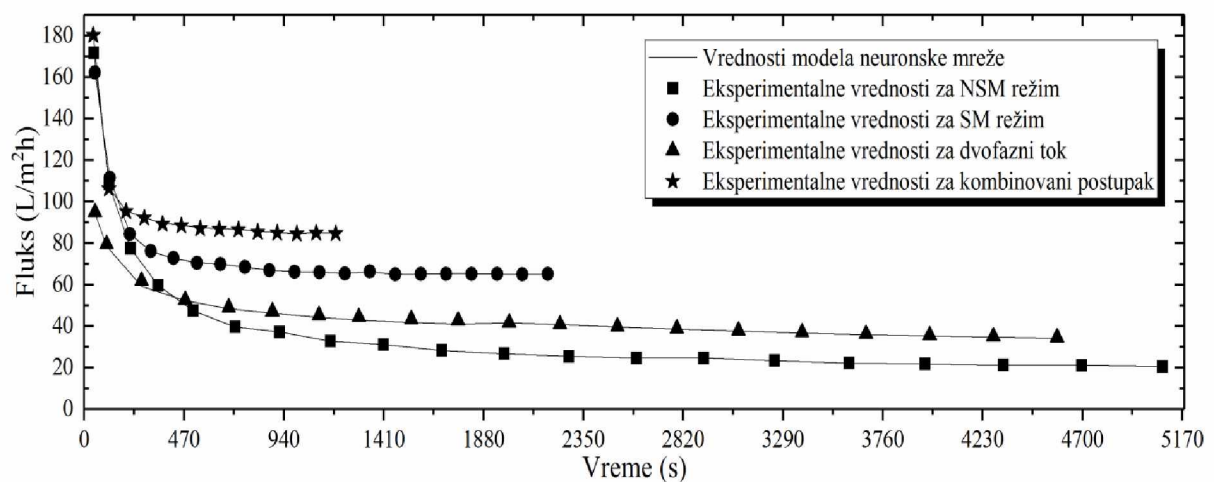
Tabela 6.5.1. Distribucija apsolutne relativne greške objedinjenih podataka

Apsolutna relativna greška (%)		<1	<5	<10	<20	>20	suma
Metode	Broj podataka	274	470	199	108	64	1115
poboljšanja							
fluksa	%	25	42	18	10	6	100

U slučaju objedinjenih rezultata mikrofiltracije sa primenom svih metoda poboljšanja fluksa permeata distribucija apsolutne relativne greške pokazala je nešto lošije rezultate u odnosu na vrednosti dobijene za pojedinačne režime primene dvofaznog toka i kombinovanog postupka. Naime, vrednost apsolutne relativne greške modela sa objedinjenim rezultatima manja je od 5% za 67% podataka (tabela 6.5.1), dok je u uslovima primene dvofaznog toka i u uslovima primene kombinovanog postupka manja od 5% za više od 70% podataka (tabele 6.3.1 i 6.4.1). Rezultati distribucije apsolutne relativne greške objedinjavanja svih metoda poboljšanja fluksa permeata lošiji su i u odnosu na vrednosti dobijene za mikrofiltraciju u uslovima recirkulacije napojne smeše gde je vrednost apsolutne relativne greške manja od 5% za više od 80% podataka u oba režima (tabela 6.2.1). Ipak, s obzirom na to da model sa objedinjenim rezultatima koristi značajno veći broj ulaznih podataka i postiže predviđanja sa apsolutnom relativnom greškom manjom od 20% za 95% podataka, čini pristup veštačke neuronske mreže odgovarajućim za predviđanje fluksa

permeata mikrofiltracije kultivacione tečnosti *Bacillus velezensis*, pogotovo u slučajevima kada je procena fluksa permeata onemogućena zbog nedovoljnog formulisanja funkcionalne zavisnosti između ulazno izlaznih parametara. Brzo dostizanje stacionarnog stanja mikrofiltracionog sistema u kom su primenjene hidrodinamičke metode za poboljšanje fluksa permeata (primena statičkog mešača, uduvanje vazduha i kombinacija ove dve metode) takođe doprinosi ovakvim rezultatima.

Generalizacijski kapacitet modela neuronske mreže potvrđen je komparativnom analizom dobijenih simulacionih rezultata na eksperimentalnim podacima koji nisu bili predstavljeni neuronskoj mreži u fazi obuke, validacije i testiranja. Eksperimenti mikrofiltracije su izvršeni na temperaturi od 25°C za transmembranski pritisak od 0,2 bar, prividnu brzinu napojne suspenzije 0,43 m/s i prividnu brzinu vazduha 0,2 m/s, a zatim su predstavljeni neuronskoj mreži.



Slika 6.5.4. Verifikacija modela neuronske mreže za denormalizovane vrednosti fluksa permeata u uslovima primene svih ispitivanih metoda poboljšanja fluksa permeata

Može se zaključiti da usvojena arhitektura neuronske mreže na zadovoljavajući način može simulirati ponašanje fluksa permeata tokom mikrofiltracije kultivacione tečnosti mikroorganizma *Bacillus velezensis* potpomognute hidrodinamičkim metodama poboljšanja fluksa permeata pošto se, kao što se može videti na slici 6.5.4., poklapaju vrednosti fluksa permeata predviđenih neuronskom mrežom i rezultata koji su dobijeni eksperimentalnim putem kod svih primenjenih metoda.

Već u početnoj fazi mikrofiltracije dolazi do pada fluksa permeata usled precipitacije ćelija mikroorganizama na površinu membrane uzrokujući povećanje specifičnog otpora

proticanju permeata (slika 6.5.4). Najmanje početne vrednosti fluksa permeata dobijene su u uslovima dvofaznog toka. Početne vrednosti fluksa permeata u uslovima dvofaznog toka manje su i od vrednosti dobijene tokom mikrofiltracije u uslovima recirkulacije napojne smeše bez primene metoda za poboljšanje fluksa permeata. Ovakvi rezultati mogu da se objasne smanjenom efektivnom površinom membrane usled zauzimanje jednog dela pora velikim mehurovima vazduha pri čepovitom režimu proticanja, kao i otporom proticanju usled formiranja komprimovaniye filtracione pogače uzrokovane uduvavanjem vazduha. Ovom zaključku doprinosi i to da mikroorganizmi soja *Bacillus velezensis* karakterističnog štapićastog oblika ćelija teže uspostavljanju kompaktnije strukture filtracione pogače usled specifične prostorne organizacije horizontalnog slaganja do koje su došli Mota i sar. (2002) ispitujući uticaj oblika ćelije na specifičnu otpornost filtracione pogače. Odmicanjem procesa mikrofiltracije u uslovima dvofaznog toka uočavaju se veće vrednosti fluksa permeata od vrednosti dobijene u uslovima recirkulacije napojne smeše bez primene statičkog promotora turbulencije. To znači da uticaj režima proticanja vazduha ipak doprinosi poboljšanju fluksa permeata uzrokujući nestabilno proticanje koje povećava napon smicanja oko velikih mehurova vazduha u tečnosti utičući na narušavanje sloja koncentracione polarizacije i strukture formirane filtracione pogače čime se poboljšava prenos mase kroz membranu i brzo dostizanje stacionarnog stanja. Postavljanje promotora turbulencije u kanal membrane, kao što se može videti na slici 6.5.4., uveliko doprinosi većim početnim vrednostima i manjem padu fluksa permeata sa vremenom u odnosu na mikrofiltraciju u uslovima dvofaznog toka i uslovima bez primene promotora turbulencije. Ovakvi rezultati su očekivani s obzirom da geometrija helikoidnih elemenata statičkog mešača pojačava radijalno mešanje uslovljavajući kretanje struje fluida bliže površini membrane što povećava brzinu smicanja na površini membrane rezultujući smanjenim nakupljanjem filtracione pogače. Obe metode povećanja fluksa permeata utiču na smanjenje spoljašnjeg prljanja membrane i koncentracione polarizacije, kao i brzinu dostizanja stacionarnog stanja, ali se može zaključiti da turbulentan režim proticanja izazvan postavljanjem statičkog mešača mnogo više utiče na smanjenje unutrašnjg prljanja membrane. Razlog za ovaj zaključak proizilazi iz helikoidne putanje i lokalnih vrtloženja statičkog mešača koji odlaže adsorpciju mikroorganizama i makromolekula, ali i ćelijskih ostataka, proteina, izlučevina mikroorganizama i drugih čestica na zidove pora membrane odnosno smanjuje uticaj biološkog prljanja koje je karakteristično za guste suspenzije kao što je kultivaciona smeša. Ovi zaključci su u korelaciji sa rezultatima optimizacije procesa unakrsne mikrofiltracije suspenzije *Chlorella sp.* u uslovima dvofaznog

toka (Javadi i sar., 2014) i ispitivanjem uticaja dvofaznog toka na bistrenje ananasovog vina (Youravong i sar., 2010) gde autori navode da uduvavanje vazduha može povećati fluks permeata smanjujući reverzibilno prljanje membrane, međutim ne može uticati na ireverzibilno prljanje membrane. Najveće vrednosti fluksa permeata i najbrže dostizanje stacionarnog stanja postignuto je u uslovima kombinovane primene difuznog toka i statičkog mešača. Veće vrednosti fluksa permeata u uslovima kombinovane primene dvofaznog toka i promotora turbulencije posledica su jače sile smicanja koje vrši turbulento nestacionarno proticanje izazvano uduvavanjem vazduha u tok napojne smeše i radijalnim mešanjem sa lokalnim vrtloženjima u spiralama promotora turbulencije koje utiče na razbijanje graničnog sloja na zidu membrane i olakšava odnošenje deponovanih čestica filtracione pogače.

6.5.2. Relativni značaj ulaznih promenljivih objedinjenih podataka mikrofiltracije kultivacione tečnosti *Bacillus velezensis*

Relativni doprinosi uticaja ulaznih promenljivih (vreme mikrofiltracije, transmembranski pritisak, prividna brzina napojne smeše i prividna brzina vazduha i primena statičkog mešača) na fluks permeata prilikom mikrofiltracije kultivacione tečnosti proizvodnog mikroorganizma *Bacillus velezensis* u uslovima primene svih svih metoda poboljšanja izračunati pomoću Garson-ove jednačine (6.1.) prikazani su u tabeli 6.5.2. Iz prikazanih rezultata može se videti da vreme filtracije ima najvažniju ulogu u određivanju pada fluksa permeata (nešto više od 50%). Ovakvi rezultati su u korelaciji sa rezultatima dobijenim prethodnim ispitivanjima mikrofiltracije.

Debljina sloja filtracione pogače menja se sa vremenom zbog stalnog nagomilavanja novih čestica pod dejstvom pogonske sile. Usled primenjene unakrsne tehnike dolazi i do stalnog odnošenja jednog dela sloja pogače na membrani, mehanizmima molekulske i konvektivne difuzije, koji su poboljšani upotrebom promotora turbulencije i uduvavanjem vazduha. Ovaj fenomen je prisutan sve do uspostavljanja stacionarnog stanja, kada je intenzitet odnošenja komponenti sa filtracione pogače jednak intenzitetu stvaranja filtracione pogače, u kom je pad fluksa permeata sa vremenom manje izražen.

Sledeći faktor po važnosti relativnog uticaja na fluks permeata je prividna brzina vazduha sa udelom značajnosti nešto manje od 16%. Stepem značajnosti relativnog uticaja prividne brzine vazduha veći je od relativnog uticaja prividne brzine tečnosti za nešto više od

4%, što navodi na zaključak da se samo povećanjem brzine vazduha može uticati na povećanje fluksa permeata.

Tabela 6.5.2. Relativni značaj ulaznih promenljivih mikrofiltracije objedinjenih podataka

Ulazni podaci	Metode poboljšanja fluksa	
	Stepen značajnosti (%)	Rang
SM	13.13	3
Transmembranski pritisak	9.44	5
Prividna brzina vazduha	15.77	2
Prividna brzina tečnosti	11.36	4
Vreme mikrofiltracije	50.30	1
UKUPNO:	100	

Ovaj rezultat nije u potpunoj korelaciji sa prethodnim ispitivanjima u kojima relativni uticaj prividne brzine tečnosti ima veći udeo značajnosti. Analizu dodatno komplikuje uvođenje novog parametra, statičkog mešača čiji je stepen značajnosti relativnog uticaja za oko 3% manji u odnosu na stepen značajnosti relativnog uticaja prividne brzine vazduha. Pretpostavlja se da su ovakvi rezultati posledica primenjene Garson-ove metode određivanja apsolutnih vrednosti koja zanemaruje pozitivni, odnosno negativni uticaj pojedinih ulaznih parametara. Neuronske mreže tzv. „modeli crne kutije“ su sistemi koji kroz proces obuke iz prezentovanih parova podataka ulazno izlaznih veličina predviđaju odnose u procesu bez razumevanja uticaja faktora i njihovih međusobnih interakcija što je i glavni nedostatak ovih modela (Olden i Jackson, 2002, Olden i sar., 2004). Moguće objašnjenje ovakvih rezultata je u svojstvu kultivacione tečnosti mikroorganizama *Bacillus velezensis* da formira kompaktnu strukturu filtracione pogače zbog specifičnog štapićastog oblika ćelija, kao što je opisano u radu Mota i sar. (2002), čija se struktura dodatno komprimuje uticajem uduvavanja vazduha rezultujući većim otporom proticanju permeata, a samim tim i većim uticajem na pad vrednosti fluksa permeata (Hwang i Hsu, 2009). Osim toga, sinergično delovanje uduvavanja vazduha i promotora turbulencije usled narušavanja strukture filtracione pogače izazvanom intenzivnim turbulentim proticanjem može dovesti do tolikog stanjivanja debljine filtracione pogače da se omogući prolazak komponenti manjih dimenzija u pore membrane koji će dovesti do pojačanog unutrašnjeg prljanja i smanjenja vrednosti fluksa permeata. S toga se

može zaključiti da je iz ovih razloga uticaj uduvavanja vazduha na fluks permeata pokazao veći stepen značajnosti od ostalih procesnih parametara. Takođe se može izvesti zaključak da uduvavanje vazduha više negativno nego pozitivno utiče na fluks permeata. Detaljnija analiza ovog zaključaka zahteva dodatne eksperimente koji izlaze iz opsega ove disertacije, ali takođe predstavljaju dobar pravac za buduća istraživanja.

Sledeći faktor po važnosti relativnog uticaja na fluks permeata je statički promotor turbulencije sa udelom značajnosti od oko 13%. Umetanje promotora turbulencije u kanal membrane nedvosmisleno utiče na povećanje fluksa permeata što se može zaključiti prema slici 6.5.4. Statički mešač utiče na povećanje prividne brzine proticanja napojne smeše izazivajući turbulenciju uz jedinstven obrazac spiralnog vrtloženja dovodeći do pojave sekundarnih tokova i radijalnog mešanja uslovljavajući kretanje struje fluida bliže površini membrane što povećava brzinu smicanja na površini membrane (Jokić i sar., 2010). Takođe, u sistemima sa uduvavanjem vazduha prisustvo statičkog mešača doprinosi značajnoj promeni režima proticanja dvofaznog toka izazivajući pucanje i koalescenciju velikih mehurova vazduha, kao i omogućavanju da se proticanje manjih mehurova vazduha odvija bliže površini kanala membrane utičući na narušavanje strukture filtracione pogače koje smanjuje otpor proticanju uzrokujući veće vrednosti fluksa permeata i brže dostizanje stacionarnog stanja.

Udeo značajnosti relativnog uticaja prividne brzine tečnosti iznosi oko 11%. Povećanje prividne brzine unakrsnog proticanja napojne smeše izaziva turbulenciju i povećanje napona smicanja u blizini površine membrane što otežava formiranje filtracione pogače, a utiče i na odnošenje određene količine ćelija proizvodnog mikroorganizma sa površine filtracione pogače kako za sistem bez promotora turbulencije tako i za sistem sa promotorom turbulencije, sistem sa uduvavanjem vazduha i sistem kombinovane primene ove dve metode (Javadi i sar., 2014, Cabassud i sar, 2001). Uticaj prividne brzine napojne smeše svakako je veći u uslovima primene statičkog promotora i kombinovane primene difuznog toka i promotora turbulencije zbog bržeg dostizanja stacionarnog stanja usled smanjenog otpora proticanju permeata. Ovom zaključku doprinosi i veći stepen značajnosti relativnog uticaja statičkog mešača koji je za oko 2% veći od uticaja prividne brzine tečnosti. Transmembranski pritisak pokazuje dva suprotna efekta na fluks permeata: pozitivan efekat usled povećanja pogonske sile mikrofiltracije i negativan efekat koji rezultuje formiranjem kompaktnijeg sloja formirane filtracione pogače. To ukazuje da uticaj transmembranskog pritiska u velikoj meri zavisi od kompresibilnosti filtracione pogače, odnosno od komponenti koje sačinjavaju

napojnu smešu (Jokić, 2012). Specifična kompaktna struktura filtracione pogače karakteristična za mikroorganizame soja *Bacillus velezensis* usled turtuoznosti zbog nasumične prostorne organizacije ćelija i sile smicanja ispoljava veći otpor proticanju permeata u sistemima sa statičkim promotorom turbulencije i sistemima sa dvofaznim tokom, trebala bi da ukaže na visok uticaj transmembranskog pritiska (Ben Hassan i sar., 2013, Pajčin, 2019). Međutim, najmanji statistički stepen značajnosti relativnog uticaja transmembranskog pritiska na fluks permeata (nešto više od 9%) od svih ispitivanih parametara ukazuje da povećanje transmembranskog pritiska ne utiče u većoj meri na promenu fluksa permeata. Ovakav rezultat je verovatno posledica primene hidrodinamičkih metoda poboljšanja fluksa permeata koje dovode do brzog postizanja stacionarnog stanja u kom je uticaj transmembranskog pritiska manje izražen (Urošević i sar., 2018).

6.6. Modelovanje u stacionarnim uslovima

Jedna od karakteristika mikrofiltracije koja istovremeno predstavlja i njenu osnovnu manu je taloženje i akumulacija ćelija, ćelijskog sadržaja i drugih komponenti iz napojne smeše na površini i unutar membrane, koja dovodi do formiranja pogače i začepljenja pora membrane. Debljina sloja formirane pogače se menja sa vremenom usled stalnog nagomilavanja novih čestica pod dejstvom razlike pritisaka koji je glavna pogonska sila procesa mikrofiltracije. Primenom unakrsne tehnike, promotora turbulencije i uduvavanja vazduha usled izazivanja turbulentog režima proticanja dolazi do stalnog odnošenja jednog dela sloja formirane pogače mehanizmima molekulske i konvektivne difuzije (Pyron i sar., 1997). Kada se brzina odnošenja komponenti sa sloja pogače izjednači sa brzinom nanošenja novih komponenti dolazi do ustaljivanja vrednosti fluksa permeata koje rezultuje svojevrsnom dinamičkom ravnotežom odnosno, nastupanja stacionarnog stanja. Stacionarni uslovi, odnosno uslovi konstantne permeacije se praktično nikada ne uspostavljaju, već i dalje dolazi do delimičnog, blažeg taloženja i adsorpcije u porama membrane koji uzrokuju stalan pad fluksa permeata (Blake i sar., 1992). Međutim, u uslovima dinamičke ravnoteže pad fluksa permeata je toliko mali da se može zanemariti, pa se može govoriti o ustaljivanju fluksa permeata na nekoj stacionarnoj vrednosti i uspostavljanju pseudo stacionarnog stanja. Smatra se da tokom mikrofiltracije pseudo stacionarno stanje nastupa kada se vrednost fluksa permeata ne menja sa vremenom tokom 10 minuta, a tada se stacionarna vrednost fluksa permeata može regulisati podešavanjem operativnih uslova unakrsne mikrofiltracije (Vyas i sar., 2000).

Modelovanje mikrofiltracije u stacionarnim uslovima neuronskim mrežama, kojim će se baviti ovo poglavlje, pre svega se odnosi na ispitivanje efikasnosti povećanja stacionarnog fluksa permeata. Utvrđivanjem vrednosti postignutog stacionarnog fluksa procenjuje se uticaj primenjene hidrodinamičke metode na povećanje fluksa permeata u stacionarnim uslovima. Kako je efikasnost mikrofiltracije ograničena zaprljanošću membrane koja izaziva pad fluksa povećavajući potrošnju energije u procesu, za karakterizaciju prihvatljivosti hidrodinamičkih metoda poboljšanja fluksa permeata veoma bitan parametar je i specifična potrošnja energije po jedinici zapremine dobijenog permeata (jednačina 5.3). Na ovaj način se posredno preko ostvarene specifične potrošnje energije u funkciji postignutog fluksa u stacionarnom stanju ocenjuje ekonomska opravdanost primenjene metode. Opravdanost primene određene metode

poboljšanja fluksa se obezbeđuje smanjenjem specifične potrošnje energije u poređenju sa drugim ispitivanim metodama.

6.6.1. Modelovanje stacionarnog fluksa

Analiza sposobnosti predviđanja fluksa permeata u stacionarnim uslovima tokom mikrofiltracije kultivacione tečnosti *Bacillus velezensis* izvršena je, kao i u prethodnim poglavljima, na modelu neuronske mreže sa 1 skrivenim slojem neurona i ukupnim eksperimentalnim rezultatima. Optimalna arhitektura neuronske mreže kojom se postižu najbolje predikcione performanse odabrana je simulacijom 4 modela neuronskih mreža formiranih kombinacijom dva algoritma obuke (*trainlm*, *trainbr*) sa dva tipa prenosne funkcije (*tansig* i *logsig*) između ulaznog i skrivenog sloja i linearne aktivacione funkcije između skrivenog i izlaznog sloja (tabela 5.2.1). Modeli neuronskih mreža sa algoritmom rezilientnog povratnog prostiranja (*trainrp*), modeli sa algoritmom skaliranog konjugovanog gradijenta (*trainscg*) i modeli sa algoritmom jednostepenog sekantnog prostiranja greške unazad (*trainoss*) su u ovom delu ispitivanja odbačeni zbog konstantno loših rezultata predikcije kako je utvrđeno u prethodnim poglavljima sa pretpostavkom da će i prilikom modelovanja stacionarnog fluksa dati loše rezultate. Neuroni u ulaznom sloju određeni su na osnovu broja parametara variranih tokom svih prethodnih eksperimenata mikrofiltracije, a kao izlazni neuron određen je fluks u stacionarnom stanju (stacionarni fluks za sve navedene eksperimente) koji se kao funkcija ulaznih promenljivih predviđa.

Eksperimentalni podaci mikrofiltracije su pre obučavanja normalizovani primenom jednačine 5.5., a zatim su randomizovani u tri grupe: 70% za trening, 15% za verifikaciju i 15% za testiranje kako je navedeno u poglavlju 5.2 (tabela 5.2.2.). Kriterijumi prekidanja obučavanja mreže istovetni su kriterijumima primenjenim u prethodnim poglavljima. Maksimalni broj epoha je postavljen na 1500, minimalna srednja kvadratna greška na 0, a najmanji gradijent učinka na $1 \cdot 10^{-10}$.

Postignuti rezultati minimalne srednje kvadratne greške podataka za proveru obuke svih odabranih modela neuronske mreže ispitivani su postepenim povećavanjem broja neurona u skrivenom sloju počevši od minimalne strukture neuronske mreže sa jednim neuronom, a zatim je izvršeno i ispitivanje vrednosti koeficijenta determinacije (rezultati za fluks permeata tokom mikrofiltracije kultivacione tečnosti *Bacillus velezensis* u stacionarnim uslovima prikazani su u Prilogu 6, tabele P6.1 i P6.2). Gornja granica broja neurona u

skrivenom sloju podešena je na 15 za sve ispitivane modele, a da bi se postigli najbolji rezultati mreže su pokrenute 30 puta.


Prema rezultatima srednje kvadratne greške podataka za proveru, kod modela koji koristi algoritam Bayes-ove regularizacije i sigmoidalnu hiperboličnu prenosnu funkciju (*trainbr tansig*) uočava se prvo blagi, a zatim i drastičan rast vrednosti minimalne srednje kvadratne greške po dostizanju 8 neurona u skrivenom sloju. Slično ponašanje se opaža i kod modela koji koristi algoritam Bayes-ove regularizacije sa sigmoidalnom logističkom prenosnom funkcijom (*trainbr logsig*) gde prvo dolazi do blagog rasta vrednosti minimalne srednje kvadratne greške nakon 4 neurona, a zatim i drastičnog rasta po postizanju 10 neurona u skrivenom sloju. Minimalna vrednost srednje kvadratne greške za model Bayes-ove regularizacije sa sigmoidalnom hiperboličnom prenosnom funkcijom (*trainbr tansig*) od $2,46 \cdot 10^{-3}$ postignuta je za 4 neurona u skrivenom sloju, dok je za model Bayes-ove regularizacije sa sigmoidalnom logističkom prenosnom funkcijom (*trainbr logsig*) minimalna vrednost srednje kvadratne greške od $3,28 \cdot 10^{-3}$ postignuta sa 5 neurona u skrivenom sloju. Očigledno je da modeli neuronske mreže sa algoritmom Bayes-ove regularizacije nisu u stanju aproksimirati zadate nelinearne odnose na ispravan način što ukazuje na problem prevelike specijalizacije modela zbog preobučavanja mreže.

Da bi se izbegao problem sa specijalizacijom mreže, a zadržala visoka predikcija za optimalne algoritme obučavanja neuronske mreže, pronalaženje optimalne arhitekture mreže i aproksimaciju eksperimentalnih rezultata odabrani su model sa Levenberg–Marquardt-ovim algoritmom i sigmoidalnom hiperboličnom prenosnom funkcijom i model sa Levenberg–Marquardt-ovim algoritmom i sigmoidalnom logističkom prenosnom funkcijom.

Prema slici 6.6.1. može se videti da u slučaju sigmoidalne hiperbolične prenosne funkcije pri Levenberg–Marquardt-ovom algoritmu treninga (*trainlm tansig*), kao i u slučaju korišćenja sigmoidalne logističke prenosne funkcije pri istom algoritmu treniranja (*trainlm logsig*), sa povećanjem broja neurona u skrivenom sloju dolazi do pada srednje kvadratne greške (bliže postavljenoj ciljnoj vrednosti treninga) što ukazuje na dobru predikcionu sposobnost mreže (slika 6.6.1.).


Kada je dostignuto 9 neurona u skrivenom sloju u slučaju Levenberg–Marquardt-ovog algoritma sa sigmoidalnom hiperboličnom funkcijom (*trainlm tansig*) uočava se blaži rast vrednosti minimalne srednje kvadratne greške, međutim daljim povećanjem broja neurona ponovo dolazi do pada ove vrednosti. Posmatrajući vrednost koeficijenta determinacije (slika 6.6.2.) zapaza se konstantan rast vrednosti sa povećanjem broja neurona u skrivenom sloju do

9 kada se uočava blagi pad, a zatim ponovni rast vrednosti koeficijenta determinacije. Može se reći da povećanje broja neurona u skrivenom sloju ne doprinosi značajno poboljšanju predikcije mreže tako da se može usvojiti arhitektura mreže sa jednim skrivenim slojem u kom se nalazi 8 neurona. Za Levenberg–Marquardt-ov algoritam sa sigmoidalnom hiperboličnom funkcijom (*trainlm tansig*) za 8 neurona u skrivenom sloju vrednosti srednje kvadratne greške i koeficijenta determinacije iznose $1,24 \cdot 10^{-4}$ i 0,99694, respektivno.



Slika 6.6.1. Varijacija vrednosti srednje kvadratne greške sa brojem neurona skrivenog sloja mikrofiltracije kultivacione smeše *Bacillus velezensis* u stacionarnim uslovima

U slučaju Levenberg–Marquardt-ovog algoritma sa sigmoidalnom logističkom prenosnom funkcijom (*trainlm logsig*) kao i kod prethodnog modela uočava se konstantan pad vrednosti minimalne srednje kvadratne greške sa povećanjem broja neurona u skrivenom sloju do 9 kada se uočava blagi rast vrednosti. Daljim povećanjem broja neurona dolazi do manjeg pada vrednosti minimalne srednje kvadratne greške. Međutim, pri dostizanju 11 neurona u skrivenom sloju uočava se ponovni rast minimalne srednje kvadratne greške, a nakon toga ponovo dolazi do pada vrednosti minimalne srednje kvadratne greške sa povećanjem broja neurona u skrivenom sloju.



Slika 6.6.2. Varijacija vrednosti koeficijenta determinacije sa brojem neurona skrivenog sloja mikrofiltracije kultivacione smeše *Bacillus velezensis* u stacionarnim uslovima

Posmatrajući ponašanje koeficijenta determinacije uočava se stalni rast vrednosti sa povećanjem broja neurona u skrivenom sloju do 13 kada se i dostiže maksimalna vrednost. Daljim povećanjem broja neurona u skrivenom sloju uočava se pad vrednosti koeficijenta determinacije. Može se reći da povećanje broja neurona u skrivenom sloju iznad 8 ne doprinosi poboljšanju predikcije mreže, pa se može usvojiti arhitektura mreže sa jednim skrivenim slojem u kom se nalazi 8 neurona. Vrednosti srednje kvadratne greške i koeficijenta determinacije za 8 neurona u skrivenom sloju kod Levenberg–Marquardt-ovog algoritma sa sigmoidalnom logističkom prenosnom funkcijom (*trainlm logsig*) iznose $1,46 \cdot 10^{-5}$ i 0,99827 respektivno. Primećuje se da kod ovog modela veći broj neurona povećava kompleksnost strukture veštačke neuronske mreže, ali značajno ne poboljšava ponašanje mreže. Na osnovu dobijenih rezultata može se izvesti zaključak da iako dolazi do poboljšanja performansi mreže javlja se neodređena sposobnost generalizacije postavljene arhitekture neuronske mreže.

Na osnovu toga se može zaključiti da vrednost srednje kvadratne greške modela sa Levenberg–Marquardt-ovim algoritmom i sigmoidalnom hiperboličnom funkcijom (*trainlm tansig*) više konvergira postavljenoj ciljnoj vrednosti, što ukazuje na bolju moć predviđanja.

Prema tome, optimalna arhitektura neuronske mreže je odabrana kao 4-8-1 sa hiperboličnom sigmoidalnom funkcijom prenosa i algoritmom treniranja Lavenberg-Marquardt.

6.6.1.1. Validacija i verifikacija modela neuronske mreže u uslovima stacionarnog fluksa

Tačnost predikcije modela neuronske mreže da na osnovu zadatih ulaznih parametara procesa mikrofiltracije predvidi vrednost fluksa u stacionarnim uslovima procenjena je preko Pearson-ovog koeficijenta korelacije i koeficijenta determinacije. Vrednost Pearson-ovog korelacionog koeficijenta od 0,99988 sugerise na dobru linearnu korelaciju između eksperimentalnih podataka i podataka predviđenih neuronskom mrežom, što se može potvrditi dijagramom na slici 6.6.3.


Vrednost koeficijenta determinacije od 0,99976 ukazuje da linearna regresiona jednačina modela za fluks permeata u stacionarnom stanju ne može da objasni manje od oko 0,03% varijacija u sistemu. Drugim rečima, 99,98% podataka je najbliže liniji najboljeg fitovanja (puna linija na slici 6.6.3. koja predstavlja idealno fitovanje linearnim modelom) što pokazuje veoma dobru pouzdanost predviđanja modela neuronske mreže, odnosno zadovoljavajuću aproksimaciju rezultata.

Raspored tačaka na slici 6.6.3. pokazuje na veoma dobro podudaranje normalizovanih eksperimentalno dobijenih vrednosti stacionarnog fluksa i normalizovanih vrednosti koje su predviđene neuronskom mrežom što znači da formirani model neuronske mreže može sa znatnom tačnošću predvideti promene realnih vrednosti stacionarnog fluksa permeata.

Detaljnija procena predviđanja stacionarnog fluksa permeata unakrsne mikrofiltracije *Bacillus velezensis* (koristeći sve ispitivane metode poboljšanja fluksa permeata) modelom neuronske mreže izvršena je analizom raspodele apsolutne relativne greške. Prema tabeli 6.6.1 model neuronske mreže je bio u stanju predvideti 96% podataka sa greškom manjom od 10%. Pri tom za 90% podataka vrednost apsolutne relativne greške manja je od 5%, a samo 2% podataka ima apsolutnu relativnu grešku veću od 20%.

Interesantno je uočiti bolje vrednosti greške predviđanja fluksa u stacionarnim uslovima u odnosu na vrednosti dobijene za objedinjene podatke koji su iskorišćeni za dobijanje jedinstvenog modela neuronske mreže za simulaciju svih metoda poboljšanja fluksa (tabela 6.5.1.). Ovakvi rezultati mogu da se objasne intenzivnijom promenom fluksa permeata u dinamičkom režimu rada mikrofiltracionog sistema koji su posledica uticaja

primene metoda poboljšanja fluksa permeata za razliku od uslova u stacionarnom stanju gde je ovaj stepen promene manje intenzivan.




Slika 6.6.3. Dijagram linearne regresije mikrofiltracije kultivacione tečnosti *Bacillus velezensis* u stacionarnim uslovima

Tabela 6.6.1. Distribucija apsolutne relativne greške predviđanja stacionarnog fluksa

Apsolutna relativna greška (%)		<1	<5	<10	<20	>20	suma
Stacionarni fluks	Broj podataka	39	4	3	1	1	48
	%	81	8	6	2	2	100

Generalizacijski kapacitet modela neuronske mreže potvrđen je komparativnom analizom dobijenih simulacionih rezultata na eksperimentalnim podacima koji nisu bili predstavljeni neuronskoj mreži u fazi obuke, validacije i testiranja. Eksperimenti mikrofiltracije su izvršeni na temperaturi od 25°C za transmembranski pritisak od 0,6 bar, prividnu brzinu napojne suspenzije od 0,43 m/s i prividnu brzinu vazduha od 0,4 m/s, a zatim su predstavljeni neuronskoj mreži.

Može se zaključiti da usvojena arhitektura neuronske mreže na zadovoljavajući način može simulirati ponašanje stacionarnog fluksa permeata tokom mikrofiltracije kultivacione tečnosti mikroorganizma *Bacillus velezensis* pošto se, kao što se može videti na slici 6.6.4., poklapaju vrednosti fluksa permeata predviđenih neuronskom mrežom i rezultata koji su dobijeni eksperimentalnim putem kod svih primenjenih metoda.



Slika 6.6.4. Verifikacija modela neuronske mreže za denormalizovane vrednosti stacionarnog fluksa

Primećuje se da su u uslovima kombinovane primene dvofaznog toka i promotora turbulencije postignute najveće vrednosti fluksa permeata u stacionarnom stanju. Upotreba kombinacije promotora turbulencije i uduvavanja vazduha rezultuje porastom fluksa u stacionarnom stanju za oko 102% u odnosu na sistem sa dvofaznim tokom, odnosno oko 27% u odnosu na sistem sa promotorom turbulencije i čak oko 240% u odnosu na sistem bez promotora turbulencije (slika 6.6.4). Veće vrednosti stacionarnog fluksa permeata u uslovima kombinovane primene dvofaznog toka i promotora turbulencije mogu da se objasne jačom silom smicanja koju izaziva nestacionarnost proticanja smeše tečnosti i vazduha sa turbulencijom izazvanom pojačanim radijalnim mešanjem i lokalnim vrtloženjima u spiralama helikoidnih elemenata promotora turbulencije koja olakšava odnošenje već deponovanih čestica sa filtracione pogače i sprečava novo deponovanje mikroorganizama i njihovih metabolita na površini membrane stvarajući porozniju strukturu filtracione pogače i omogućujući postizanje većih vrednosti fluksa permeata. Turbulencija koju pospešuju promotor turbulencije i uduvavanje vazduha utiču na brzo ustaljivanje debljine filtracione

pogače i uspostavljanje stacionarnog stanja. Velike vrednosti stacionarnog fluksa permeata uočavaju se i u uslovima primene statičkog mešača koje takođe mogu da se objasne turbulentim režimom proticanja.

Najmanji uticaj na porast stacionarnog fluksa permeata ima metod uduvavanja vazduha i unakrsna mikrofiltracija bez primene promotora tubulencije. Manje vrednosti stacionarnog fluksa permeata u uslovima dvofaznog toka mogu da se objasne uticajem uduvavanja vazduha na stvaranje komprimovaniye filtracione pogače zbog karakteristične specifične prostorne organizacije ćelija mikroorganizama soja *Bacillus velezensis* u strukturi filtracione pogače i nedovoljnoj efikasnosti postignutog režima proticanja da utiče na povećanje turbulencije napojne smeše i smanjenje debljine filtracione pogače. Do sličnih zaključaka su došli i drugi autori koji smatraju da režim čepovitog proticanja velikih mehurova verovatno doprinosi kompaktnijoj strukturi pogače, a time i manjiim vrednostima fluksa permeata (Hwang i Hsu, 2009, Youravong i sar., 2010, Hwang i Chen, 2010). Specifična prostorna organizacija horizontalnog slaganja štapićastih oblika ćelija karakteristična za mikroorganizme soja *Bacillus valensis* koja utiče na uspostavljanje kompaktnije filtracione pogače uzrok je male vrednosti stacionarnog fluksa i u sistemu unakrsne mikrofiltracije bez promotora turbulencije.

6.6.1.2. Relativni značaj ulaznih promenljivih mikrofiltracije u stacionarnim uslovima

Relativni doprinosi uticaja ulaznih promenljivih (vreme mikrofiltracije, transmembranski pritisak, prividna brzina napojne smeše, prividna brzina vazduha i primena statičkog mešača) na fluks permeata prilikom mikrofiltracije kultivacione tečnosti proizvodnog mikroorganizma *Bacillus velezensis* u stacionarnim uslovima izračunati pomoću Garson-ove jednačine (6.1.) prikazani su u tabeli 6.6.2. Iz prikazanih rezultata može se videti da prividna brzina tečnosti ima najvažniju ulogu u određivanju porasta fluksa permeata u stacionarnim uslovima (nešto više od 28%).

Ovakvi rezultati su očekivani jer se sa porastom brzine proticanja smanjuje debljina pogače koja predstavlja dominantan otpor procesu mikrofiltracije. Uticaj prividne brzine unakrsnog proticanja napojne smeše na porast fluksa permeata u stacionarnom stanju ogleda se u prelasku iz laminarnog strujanja u turbulentni režim koji utiče na odnošenje određene

količine ćelija sa površine filtracione pogače, a i povećanju napona smicanja u blizini površine membrane koji otežava dalje deponovanje ćelija i povećanje debljine filtracione pogače. Međutim, to znači da će povećanje prividne brzine napojne smeše rezultovati većim porastom fluksa u stacionarnom stanju i bez primene metoda za poboljšanje fluksa.

Tabela 6.6.2. Relativni značaj ulaznih promenljivih na predviđanje stacionarnog fluksa

Ulazni podaci	Stacionarni fluks	
	Stepen značajnosti (%)	Rang
SM	20,75	4
Transmembranski pritisak	23,56	3
Prividna brzina vazduha	26,96	2
Prividna brzina tečnosti	28,73	1
UKUPNO:	100	

Očigledno je da promotor turbulencije utiče na kretanje toka napojne smeše u blizini površine membrane uz jedinstven obrazac spiralnog vrtloženja i radijalnog mešanja izazivajući povećanje prividne brzine proticanja napojne smeše duž membrane u odnosu na brzinu protoka suspenzije u sistemu. Do sličnih zaključaka su došli Jokić (2012) modelujući mikrofiltraciju suspenzije kvasca i Šereš i sar. (2018) ispitujući mogućnost modelovanja mikrofiltracije otpadnih voda industrije skroba postupkom odzivne površine. Uticaj privide brzine napojne smeše na porast fluksa svakako je veći u uslovima primene statičkog promotora i kombinovane primene difuznog toka i promotora turbulencije zbog bržeg dostizanja stacionarnog stanja usled smanjenog otpora proticanju permeata.

Sledeći faktor po važnosti uticaja na porast fluksa u stacionarnim uslovima je prividna brzina vazduha sa stepenom značajnosti od oko 27%. Interesanto je uočiti približno slične vrednosti stepena značajnosti uticaja prividne brzine tečnosti i prividne brzine vazduha na porast fluksa permeata u stacionarnim uslovima koji navodi na zaključak o sinergičnom delovanju ova dva parametra. Ova konstatacija može da se objasni većim uticajem režima proticanja od pojedinačnih prividnih brzina proticanja vazduha i tečnosti. Nestabilno proticanje izazvano uduvavanjem vazduha u tok napojne smeše povećava turbulenciju i napon smicanja na površini membrane koji dovodi do pomeranja slabovezanih koloidnih čestica i makromolekula sa površine formirane pogače ali i do kidanja adsobovanog sloja

usled pucanja i koalescencije velikih mehurova gasa (režim čepovitog proticanja) dovodeći do smanjenja mase filtracione pogače. Slični zaključci, koji pokazuju da režim proticanja ima veći uticaj od pojedinačnih brzina proticanja gde je porast fluksa u stacionarnim uslovima posledica čepovitog režima proticanja velikih mehurova mogu se pronaći i u literaturi (Hwang i Hsu, 2009, Pajčin, 2019). Rezultati tih istraživanja pokazuju da pri malim brzinama proticanja tečne faze masa filtracione pogače kontinualno opada sa povećanjem brzine proticanja gasa. Autori takođe zaključuju da struktura filtracione pogače pri većim brzinama proticanja tečne faze postaje kompaktnija zahvaljujući dvofaznom toku i da je ovaj uticaj veći sa povećanjem brzine proticanja napojne smeše.

Uticaj transmembranskog pritiska na porast fluksa permeata u stacionarnom stanju sa stepenom značajnosti od oko 24% manje je izražen. Relativni uticaj transmembranskog pritiska na porast fluksa u stacionarnim uslovima je za nešto više od 5% manji od relativnog uticaja protoka napojne suspenzije i za nešto više od 3% manji od relativnog uticaja prividne brzine vazduha tako da se može zaključiti da se fluks permeata može efikasno povećati samo promenom režima proticanja napojne smeše. Ovi rezultati su u korelaciji sa rezultatima optimizacije procesa unakrsne mikrofiltracije suspenzije *Chlorella sp.* (Javadi i sar., 2014). Ovakav rezultat takođe ukazuje da kompresibilnost filtracione pogače, koja ispoljava veći otpor proticanju u stacionarnom stanju predstavlja dominantni faktor koji utiče na porast fluksa permeata. Do sličnih zaključaka su došli i Jokić i sar. (2010) ispitujući efekat promotora turbulencije na mikrofiltraciju suspenzije kvasca. Dizajn promotora turbulencije uzrokuje specifični obrazac turbulentnog proticanja koji doprinosi narušavanju strukture filtracione pogače, a u slučaju kombinacije sa uduvavanjem vazduha može da utiče na narušavanje filtracione pogače u tolikoj meri da se omogući prodiranje komponenti manjih dimenzija u pore membrane.

Najmanji uticaj na fluks u stacionarnom stanju pokazao je statički promotor turbulencije sa udelom značajnosti od oko 21%. Umetanje promotora turbulencije u kanal membrane nedvosmisleno utiče na porast fluksa permeata u stacionarnom stanju kao što se vidi na slici 6.6.4. Najmanja vrednost relativnog uticaja statičkog promotora navodi na zaključak da se veće vrednosti fluksa permeata u stacionarnom stanju mogu dobiti samo podešavanjem procesnih parametara i bez prisustva promotora turbulencije. Međutim, statički mešač utiče na hidrodinamički režim u kanalu membrane dovodeći do turbulencije koja omogućuje da struja fluida utiče na narušavanje strukture filtracione pogače i smanjenje specifičnog otpora proticanju permeata tako da se može reći da u stacionarnim uslovima fluks

permeata zavisi samo od stepena komprimovanja sloja na membrani. Moguće objašnjenje ovih rezultata je u tome da su neuronske mreže tzv. „modeli crne kutije“ sistemi koji kroz proces obuke iz prezentovanih parova podataka ulazno izlaznih veličina predviđaju odnose u procesu bez razumevanja uticaja faktora i njihovih međusobnih interakcija što je i glavni nedostatak ovog modela (Olden i Jackson, 2002, Olden i sar., 2004).

6.6.2. Modelovanje specifične potrošnje energije

Kako bi se dobila jedinstvena neuronska mreže za simulaciju specifične potrošnje energije u stacionarnim uslovima mikrofiltracije kultivacione tečnosti *Bacillus velezensis* analiza sposobnosti predviđanja, kao i u prethodnim poglavljima, izvršena je na modelu neuronske mreže sa 1 skrivenim slojem neurona i ukupnim eksperimentalnim rezultatima. Optimalna arhitektura neuronske mreže kojom se postižu najbolje predikcione performanse odabrana je simulacijom 4 modela neuronskih mreža formiranih kombinacijom pet algoritama obuke (*trainlm*, *trainbr*, *trainrp*,) sa dva tipa prenosne funkcije (*tansig* i *logsig*) između ulaznog i skrivenog sloja i linearne aktivacione funkcije između skrivenog i izlaznog sloja (tabela 5.2.1). U ovom delu ispitivanja modeli neuronskih mreža sa algoritmom rezilientnog povratnog prostiranja (*trainrp*), modeli sa algoritmom skaliranog konjugovanog gradijenta (*trainscg*) i modeli sa algoritmom jednostepenog sekantnog prostiranja greške unazad (*trainoss*) su odbačeni pod pretpostavkom da će kao i kod prethodnih ispitivanja dati loše rezultate predikcije. Neuroni u ulaznom sloju određeni su na osnovu broja parametara variranih tokom svih prethodnih eksperimenata mikrofiltracije, a kao izlazni neuron određena je specifična potrošnja energije koja se kao funkcija ulaznih promenljivih predviđa.

Eksperimentalni podaci mikrofiltracije su pre obučavanja normalizovani primenom jednačine 5.5., a zatim su randomizovani u tri grupe: 70% za trening, 15% za verifikaciju i 15% za testiranje kako je navedeno u poglavlju 5.2 (tabela 5.2.2.). Kriterijumi prekidanja obučavanja mreže istovetni su kriterijumima primenjenim u prethodnim poglavljima. Maksimalni broj epoha je postavljen na 1500, minimalna srednja kvadratna greška na 0, a najmanji gradijent učinka na $1 \cdot 10^{-10}$.

Postignuti rezultati minimalne srednje kvadratne greške podataka za proveru obuke svih odabranih modela neuronske mreže ispitivani su postepenim povećavanjem broja neurona u skrivenom sloju počevši od minimalne strukture neuronske mreže sa jednim neuronom, a zatim je izvršeno i ispitivanje vrednosti koeficijenta determinacije (rezultati za


specifičnu potrošnju energije mikrofiltracije kultivacione tečnosti *Bacillus velezensis* u stacionarnim uslovima prikazani su u Prilogu 6, tabele P6.3 i P6.4). Gornja granica broja neurona u skrivenom sloju podešena je na 15 za sve ispitivane modele, a da bi se postigli najbolji rezultati mreže su pokrenute 30 puta.

Prema rezultatima srednje kvadratne greške podataka za proveru, očigledno je da modeli koji koriste algoritam Bayes-ove regularizacije i sigmoidalnu hiperboličnu prenosnu funkciju (*trainbr tansig*) i algoritam Bayes-ove regularizacije sa sigmoidalnom logističkom prenosnom funkcijom (*trainbr logsig*) pokazuju veoma slabu generalizaciju i efekte pretreniranja, tako da neće biti u stanju aproksimirati zadate nelinearne odnose na ispravan način. Naime, vrednost minimalne srednje kvadratne greške kod oba modela se neznatno menja sa povećanjem broja neurona u skrivenom sloju (vrednosti se kreću oko $2,65 \cdot 10^{-2}$). U slučaju modela koji koristi Bayes-ovu regularizaciju sa hiperboličnom sigmoidalnom prenosnom funkcijom vrednost koeficijenta determinacije u većini slučajeva nije mogla biti utvrđena, a kod modela koji koristi sigmoidalnu logističku prenosnu funkciju maksimalna vrednost od 0,69636 je dobijena za 15 neurona u skrivenom sloju. Može se reći da mreža obučavana modelom koji koristi algoritam Bayes-ove regularizacije nije u stanju da nauči zakonitosti koje vladaju u procesu mikrofiltracije ili ih nije naučila nego samo memoriše podatke iz skupa za obučavanje.

S toga, da bi se zadržala visoka predikcija i izbegao problem sa specijalizacijom mreže, za optimalne algoritme obučavanja neuronske mreže, pronalaženje optimalne arhitekture mreže i aproksimaciju eksperimentalnih rezultata odabrani su modeli koji koriste Levenberg–Marquardt-ov algoritam sa sigmoidalnom hiperboličnom prenosnom funkcijom i sigmoidalnom logističkom prenosnom funkcijom.

Prema slici 6.6.5 može se videti da u slučaju Levenberg–Marquardt-ovog algoritma sa sigmoidalnom hiperboličnom funkcijom (*trainlm tansig*) povećanje broja neurona u skrivenom sloju rezultuje dobrom sposobnošću predviđanja pošto se minimalna srednja kvadratna greška približava ciljnoj graničnoj vrednosti postavljenoj za trening. Povećanjem broja neurona u skrivenom sloju na više od 7 uočava se neznatna promena, skoro stagnacija vrednosti minimalne srednje kvadratne greške. Isto ponašanje se uočava i kod vrednost koeficijenta determinacije (slika 6.6.6). Može se reći da povećanje broja neurona u skrivenom sloju ne doprinosi značajno poboljšanju predikcije mreže tako da se može usvojiti jednostavnija arhitektura mreže sa jednim skrivenim slojem u kom se nalazi 7 neurona. Za Levenberg–Marquardt-ov algoritam sa sigmoidalnom hiperboličnom funkcijom (*trainlm*


tansig) sa 7 neurona u skrivenom sloju vrednosti srednje kvadratne greške i koeficijenta determinacije iznose $2,50 \cdot 10^{-3}$ i 0,96942, respektivno.



Slika 6.6.5. Varijacija vrednosti srednje kvadratne greške sa brojem neurona skrivenog sloja mikrofiltracije kultivacione smeše *Bacillus velezensis* u stacionarnim uslovima za specifičnu potrošnju energije

U slučaju Levenberg–Marquardt-ovog algoritma treninga sa sigmoidalnom logističkom prenosnom funkcijom (*trainlm logsig*) kao i kod prethodnog modela uočava se konstantan pad vrednosti minimalne srednje kvadratne greške sa povećanjem broja neurona u skrivenom sloju do 11 kada se uočava blagi rast vrednosti. Daljim povećanjem broja neurona dolazi do manjeg pada vrednosti minimalne srednje kvadratne greške. Posmatrajući ponašanje koeficijenta determinacije uočava se stalni rast vrednosti sa povećanjem broja neurona u skrivenom sloju do 8 kada dolazi do manjeg pada ove vrednosti. Međutim, daljim povećanjem broja neurona u skrivenom sloju dolazi do ponovnog rasta vrednosti koeficijenta determinacije sve do 14 neurona u skrivenom sloju kada se postiže i maksimalna vrednosti koeficijenta determinacije. Može se reći da povećanje broja neurona u skrivenom sloju iznad 8 u slučaju modela koji koristi Levenberg–Marquardt-ov algoritam treninga sa sigmoidalnom logističkom prenosnom funkcijom (*trainlm logsig*) ne doprinosi poboljšanju predikcije mreže, pa se može usvojiti arhitektura mreže sa jednim skrivenim slojem u kom se nalazi 8 neurona. Vrednosti srednje kvadratne greške i koeficijenta determinacije za 8 neurona u

skrivenom sloju Levenberg–Marquardt-ovog algoritma treniranja sa sigmoidalnom logističkom prenosnom funkcijom (*trainlm logsig*) iznose $2,51 \cdot 10^{-5}$ i 0,97031, respektivno.



Slika 6.6.6. Varijacija vrednosti koeficijenta determinacije sa brojem neurona skrivenog sloja mikrofiltracije kultivacione smeše *Bacillus velezensis* u stacionarnim uslovima za specifičnu potrošnju energije

Na osnovu prethodnog, uzimajući u obzir da je osnovni cilj optimalne arhitekture neuronske mreže dobiti mrežu sa minimalnim brojem skrivenih neurona koja daje maksimalni koeficijent determinacije i minimalnu srednju kvadratnu grešku, može se zaključiti da model Levenberg–Marquardt-ov algoritam sa sigmoidalnom hiperboličnom funkcijom (*trainlm tansig*) više konvergira postavljenoj ciljnoj vrednosti. Prema tome, optimalna arhitektura neuronske mreže je odabrana kao 4-7-1 sa hiperboličnom sigmoidalnom funkcijom prenosa i algoritmom treniranja Levenberg–Marquardt.

6.6.2.1. Validacija i verifikacija modela neuronske mreže specifične potrošnje energije u stacionarnim uslovima

Pouzdanost predviđanja specifične potrošnje energije na osnovu zadatih ulaznih parametara procesa mikrofiltracije u uslovima primene svih hidrodinamičkih metoda poboljšanja fluksa permeata ocenjuje se prema tačnosti predikcije. Tačnost predikcije modela neuronske mreže procenjena je preko Pearson-ovog koeficijenta korelacije i koeficijenta determinacije. Vrednost Pearson-ovog korelacionog koeficijenta od 0,99041 sugeriše na dobru linearnu korelaciju između eksperimentalnih podataka i podataka predviđenih neuronskom mrežom, što se može potvrditi dijagramom na slici 6.6.7.

Vrednost koeficijenta determinacije od 0,98091 ukazuje da linearna regresiona jednačina modela za specifičnu potrošnju energije u stacionarnom stanju ne može da objasni manje od 2% varijacija u sistemu. Drugim rečima, 98,09% podataka je najbliže liniji najboljeg fitovanja (puna linija na slici 6.6.7. koja predstavlja idealno fitovanje linarnim modelom), što pokazuje veoma dobru pouzdanost predviđanja modela neuronske mreže, odnosno zadovoljavajuću aproksimaciju eksperimentalnih rezultata.


Raspored tačaka na slici 6.6.7. pokazuje na veoma dobro podudaranje normalizovanih eksperimentalno dobijenih vrednosti specifične potrošnje energije i normalizovanih vrednosti koje su predviđene neuronskom mrežom što znači da formirani model neuronske mreže može sa znatnom tačnošću predvideti promene realnih vrednosti potrošnje energije u stacionarnim uslovima. Detaljnija procena predviđanja specifične potrošnje energije unakrsne mikrofiltracije *Bacillus velezensis* (koristeći sve ispitivane metode poboljšanja fluksa permeata) modelom neuronske mreže izvršena je analizom raspodele apsolutne relativne greške (tabela 6.6.3).

Tabela 6.6.3. Distribucija apsolutne relativne greške predviđanja specifične potrošnje energije

Apsolutna relativna greška (%)		<1	<5	<10	<20	>20	suma
Specifična potrošnja energije	Broj podataka	13	17	9	4	5	48
	%	27	35	19	8	10	100

Prema tabeli 6.6.3 model neuronske mreže je bio u stanju predvideti 81% podataka sa greškom manjom od 10%. Pri tom za 62% podataka vrednost apsolutne relativne greške

manja je od 5%, a 10% podataka ima apsolutnu relativnu grešku veću od 20%. Interesantno je uočiti bolje vrednosti distribucije apsolutne relativne greške fluksa u stacionarnim uslovima (tabela 6.6.1.) u odnosu na vrednosti dobijene za specifičnu potrošnju energije (tabela 6.6.3).




Slika 6.6.7. Dijagram linearne regresije specifične potrošnje energije mikrofiltracije kultivacione tečnosti *Bacillus velezensis* u stacionarnim uslovima

Generalizacijski kapacitet modela neuronske mreže potvrđen je komparativnom analizom dobijenih simulacionih rezultata na eksperimentalnim podacima koji nisu bili predstavljeni neuronskoj mreži u fazi obuke, validacije i testiranja. Eksperimenti mikrofiltracije su izvršeni na temperaturi od 25°C za transmembranski pritisak od 0,6 bar, prividnu brzinu napojne suspenzije od 0,43 m/s i prividnu brzinu vazduha od 0,4 m/s, a zatim su predstavljeni neuronskoj mreži.

Može se zaključiti da usvojena arhitektura neuronske mreže na zadovoljavajući način može simulirati ponašanje specifične potrošnje energije tokom mikrofiltracije kultivacione tečnosti mikroorganizma *Bacillus velezensis* pošto se, kao što se može videti na slici 6.6.8., poklapaju vrednosti specifične potrošnje energije u stacionarnom stanju predviđene

neuronskom mrežom i rezultata koji su dobijeni eksperimentalnim putem kod svih primenjenih metoda.



Slika 6.6.8. Verifikacija modela neuronske mreže za denormalizovane vrednosti specifične potrošnje energije

Upotreba postupaka kojima se utiče na promenu hidrodinamičkog režima strujanja dovodi do povećanja pada pritiska kroz membranu što predstavlja dodatni utrošak energije (Krstić i sar., 2007, Vatai i sar., 2007). Specifična potrošnja energije predstavlja promenu pada hidrauličke snage i fluksa permeata, po jedinici zapremine permeata (jednačina 5.3), a ekonomska opravdanost primene metoda poboljšanja fluksa obezbeđuje se smanjenjem specifične potrošnje energije u odnosu na sistem bez primene metode poboljšanja fluksa (Vatai i sar., 2007). Prema slici 6.6.4. u slučaju primene statičkog promotora turbulencije postižu se veće vrednosti fluksa permeata u stacionarnom stanju u odnosu na vrednosti postignute u slučaju primene dvofaznog toka. S toga je opravdano pretpostaviti da bi pri izboru metode poboljšanja fluksa izbor promotora turbulencije prevagnuo u odnosu na metodu dvofaznog toka. Međutim, primena statičkog promotora turbulencije može dovesti do porasta pada pritiska duž membrane odnosno, povećanja snage potrebne za proticanje napojne smeše usled povećanog otpora proticanju zbog smanjenja površine poprečnog preseka kanala membrane kroz koji protiče napojna smeša dovodeći do veće potrošnje energije u odnosu na sistem sa dvofaznim tokom. Prema tome, podaci o vrednosti stacionarnog fluksa u zavisnosti od eksperimentalnih uslova mogu prikriti stvarnu efikasnost primenjene metode poboljšanja fluksa. Iz tog razloga je neophodno da porast fluksa permeata

uslovljen primenom određene metode poboljšanja može da kompenzuje povećani pad hidrauličke snage kako bi njegova primena bila opravdana sa ekonomske tačke gledišta (Jokić i sar., 2010). Upoređujući dobijene rezultate, specifična potrošnja energije sistema sa statičkim mešačem i sistema sa dvofaznim tokom pokazuje slične vrednosti, a očigledno je da kombinovan postupak primene promotora turbulencije i dvofaznog toka postiže najmanji gubitak hidrauličke snage od svih primenjenih metoda zbog čega se pokazao kao najefikasniji u pogledu specifične potrošnje energije (slika 6.6.8). Sistem kombinovane primene statičkog promotora turbulencije i dvofaznog toka postiže i veće vrednosti fluksa u stacionarnom stanju u odnosu na sve druge primenjene metode (slika 6.6.4). Slični zaključci, koji pokazuju da se kombinovanjem dvofaznog toka i statičkog mešača potrebna energija smanjuje u odnosu na sistem sa jednofaznim tokom mogu se pronaći i u literaturi (Vatai i sar., 2007).

6.6.2.2. Relativni značaj ulaznih promenljivih mikrofiltracije na specifičnu potrošnju energije u stacionarnim uslovima

Relativni doprinosi uticaja ulaznih promenljivih (vreme mikrofiltracije, transmembranski pritisak, prividna brzina napojne smeše, prividna brzina vazduha i primena statičkog mešača) na specifičnu potrošnju energije prilikom mikrofiltracije kultivacione tečnosti proizvodnog mikroorganizma *Bacillus velezensis* u stacionarnim uslovima izračunati pomoću Garson-ove jednačine (6.1.) prikazani su u tabeli 6.6.4.

Iz prikazanih rezultata može se videti da prividna brzina tečnosti ima najvažniju ulogu u određivanju specifične potrošnje energije (nešto više od 33%). Ovakav rezultat je očekivan s obzirom da povećanje protoka napojne smeše dovodi do povećanja pada pritiska u kanalu membrane što za posledicu ima gubitak hidrauličke snage, a samim tim i povećanje specifične potrošnje energije. Specifična potrošnja energije direktno je proporcionalna povećanju pada pritiska, a obrnuto proporcionalna fluksu (jednačina 5.3.), što znači da se odnos pada pritiska i fluksa u stacionarnom stanju mora održavati bar konstantnim ili smanjivati kako bi specifična potrošnja energije bila manja i omogućila efikasnost procesa (Krstić i sar., 2007, Vatai i sar., 2007). Opravdano je zaključiti da povećanje prividne brzine napojne smeše koje se obezbeđuje prelaskom iz laminarnog u turbulenti režim proticanja rezultuje povećanjem utroška energije potrebne za rad pumpe, a koji je direktno proporcionalan protoku napojne smeše.

Tabela 6.6.4. Relativni značaj ulaznih promenljivih mikrofiltracije na smanjenje potrošnje energije u stacionarnim uslovima

Ulazni podaci	Stacionarni uslovi-E	
	Stepen značajnosti (%)	Rang
SM	17,18	4
Transmembranski pritisak	24,20	3
Prividna brzina vazduha	25,18	2
Prividna brzina tečnosti	33,44	1
UKUPNO:	100	

Sledeći faktor po važnosti relativnog uticaja na specifičnu potrošnju energije je prividna brzina vazduha sa udelom značajnosti oko 25%. Povećanje prividne brzine vazduha se (kao i u slučaju povećanja prividne brzine napojne smeše) obezbeđuje povećanjem utroška energije potrebne za uduvavanje vazduha. Sa druge strane opravdano je očekivati da čepovit režim proticanja koji nastaje povećanjem prividne brzine vazduha, zbog uticaja na komprimovanje filtracione pogače, uslovljava povećanje otpora proticanju rezultujući povećanom specifičnom potrošnjom energije. Međutim rezultati pokazuju da iako povećanje prividne brzine vazduha utiče na specifičnu potrošnju energije ovaj uticaj nije tako izražen kao povećanje prividne brzine proticanja napojne smeše. Moguće objašnjenje ove pojave je da u sistemima sa uduvavanjem vazduha dolazi do manjeg otpora filtracione pogače zbog nestacionarnog proticanja dvofaznog toka koji pospešuje smanjenje debljine filtracione pogače, tako da energija potrebna za komprimovanje vazduha predstavlja svojevrsan kontrabalans redukovanju otpora filtracione pogače, a porast fluksa je dovoljno velik da kompenzuje povećani pad hidrauličke snage. Slični zaključci, koji pokazuju da povećanje specifične potrošnje energije potrebne za kompresiju vazduha kompenzuje porast fluksa u sistemima sa dvofaznim tokom i sistemima sa kombinacijom statičkog mešača i dvofaznog toka mogu se pronaći i u literaturi (Armbruster i sar., 2019).

Sledeći faktor po važnosti relativnog uticaja na specifičnu potrošnju energije ima transmembranski pritisak čiji stepen značajnosti iznosi oko 24%. Povećanje transmembranskog pritiska dovodi do povećanog nakupljanja filtracione pogače koja rezultuje većim otporom proticanju permeata, međutim sa druge strane transmembranski pritisak je glavna pogonska sila procesa mikrofiltracije. Karakterističnost kultivacione tečnosti mikroorganizama soja *Bacillus velezensis* je formiranje kompaktne strukture filtracione

pogače (kako je zaključeno u prethodnim poglavljima) koja stvara znatan otpor proticanju, pa će povećanje transmembranskog pritiska samo doprineti većoj kompresiji filtracione pogače, odnosno većem padu pritiska duž membrane, što će izazvati i povećanje specifične potrošnje energije.

Prljanje membrane rezultuje znatnim padom početne hidrauličke propusnosti što dovodi do opadanja protoka permeata tokom vremena, pa je stoga povećana potrošnja energije neophodna da bi se održala potrebna produktivnost membrane (Krstić i sar., 2002). Umetanje statičkog promotora u kanal membrane neminovno dovodi do povećanja permeabilnosti zbog visokog stepena turbulencije u blizini površine membrane koji usled povećanja protoka utiče na smanjenje filtracione pogače čak i pri malim prividnim brzinama napojne smeše. Sa druge strane umetanje statičkog mešača izaziva pad pritiska duž membrane zbog povećanog otpora proticanju, a time i povećanje specifične potrošnje energije (Krstić i sar., 2002). Ipak, najmanji relativni uticaj na specifičnu potrošnju energije koju je pokazao statički mešač sa stepenom značajnosti od oko 17% pokazuje da je ostvarena vrednost fluksa permeata dovoljno velika da kompenzuje povećanje specifične potrošnje energije. Opravdanost ove tvrdnje proizilazi iz sličnih vrednosti postignute specifične potrošnje energije mikrofiltracije sa primenom statičkog promotora turbulencije i mikrofiltracije u uslovima dvofaznog toka (slika 6.6.8). U uslovima primene oba režima (kombinovana primena statičkog mešača i dvofaznog toka) se postižu najmanje vrednosti specifične potrošnje energije tako da se ne može reći da statički promotor turbulencije ima minornu ulogu u specifičnoj potrošnji energije. Osim toga statički mešač utiče na izmenu operativnih uslova u procesu mikrofiltracije. Moguće objašnjenje najmanjeg relativnog uticaja statičkog mešača proizilazi iz toga da su modeli neuronskih mreža tzv. „*black box*“ modeli koji predviđaju odnose u procesu bez razumevanja uticaja faktora i njihovih međusobnih interakcija (Olden i sar., 2004).

7. Zaključak

Osnovni cilj istraživanja u okviru ove doktorske disertacije je da se na osnovu rezultata eksperimenta uoče i definišu određene zakonitosti u ponašanju veštačkih neuronskih mreža i na osnovu uočenih zakonitosti proceni uticaj procesnih parametara (transmembranski pritisak, protok tečnosti i vazduha i vreme filtracije) na pad fluksa permeata kako bi se razvio dinamički model zasnovan na konceptu neuronskih mreža koji će na adekvatan način simulirati ponašanje sistema i opisati zavisnosti između pojedinih parametara procesa. Takođe, jedan od ciljeva istraživanja u okviru ove doktorske disertacije bio je i razvoj modela kojim bi se objedinili eksperimentalni rezultati u cilju dobijanja jedne jedinstvene neuronske mreže za simulaciju svih metoda poboljšanja fluksa, kao i razvoj modela neuronskih mreža za procenu efikasnosti poboljšanja fluksa usled primene metoda poboljšanja fluksa permeata u stacionarnim uslovima i specifičnog smanjenja potrošnje energije.

S obzirom na složenost problematike prljanja membrane i da proces mikrofiltracije nije jednostavno i lako pratiti rezultati ispitivanja jasno pokazuju da se primenom koncepta neuronskih mreža mogu adekvatno reprezentovati eksperimentalni rezultati mikrofiltracije kultivacione smeše mikroorganizama *Streptomyces hygroscopicus* i *Bacillus velezensis*. Na osnovu dobijenih rezultata mogu se izvesti sledeći zaključci:

- Najbolju sposobnost generalizacije i predikcije pokazao je model neuronske mreže obučavan Levenberg-Markuardt-ovim algoritmom. Optimalan broj neurona u skrivenom sloju se kretao od 7 do 13 što ukazuje na znatnu kompleksnost mehanizama koji utiču na fluks permeata kako je i procenjeno postavljanjem hipoteze ove doktorske disertacije. Vrednosti koeficijenta korelacije se kreću u rasponu od 0,99041 do 0,99988 što ukazuje na odlične prediktivne mogućnosti neuronske mreže da proceni vrednost fluksa permeata bez potrebe za izvođenjem dodatnih eksperimenata mikrofiltracije u posmatranom eksperimentalnom opsegu.
- Analiza apsolutne relativne greške kod svih modela mikrofiltracije pokazala je veoma dobro predviđanje pošto je u rasponu od 81% do 100% podataka imalo grešku manju od 10%, a koeficijent determinacije u rasponu od 0,98091 do 0,99976 ukazuje da mreža ne može da objasni manje od 2% varijacija u sistemu. Nešto lošiji rezultati predviđanja modela mikrofiltracije u uslovima recirkulacije napojne smeše u odnosu na model u uslovima ugušćivanja mogu da se objasne većim brojem neurona u skrivenom sloju koji

ukazuje na kompleksnost ispitivanog sistema. Kompleksnost ispitivanog sistema može se objasniti specifičnom prostornom organizacijom štapićastih ćelija mikroorganizama *Bacillus velezensis* u toku napojne smeše i u strukturi filtracione pogače koji utiču na operativne uslove odvijanja procesa mikrofiltracije, što je u skladu sa objavljenim naučnim rezultatima ispitivanja mikrofiltracije kultivacionih smeša štapićastih oblika ćelija mikroorganizama.

- Model neuronske mreže mikrofiltracije kultivacione smeše mikroorganizma *Bacillus velezensis* u kom su objedinjeni eksperimentalni rezultati u cilju dobijanja jedne jedinstvene neuronske mreže za simulaciju svih metoda poboljšanja fluksa pokazao je odlične rezultate s obzirom da mreža nije mogla da objasni oko 0,8% varijacija u sistemu. Kako model postiže predviđanja sa apsolutnom relativnom greškom manjom od 20% za 95% podataka, a koristi značajno veći broj ulaznih podataka od svih ostalih modela, čini koncept veštačkih neuronskih mreža adekvatnim za predviđanje fluksa permeata mikrofiltracije kultivacione tečnosti *Bacillus velezensis*, pogotovo u slučajevima kada je procena fluksa permeata onemogućena zbog nedovoljnog formulisanja funkcionalne zavisnosti između ulazno izlaznih parametara.
- Relativan značaj ulaznih promenljivih dinamičkog modela istraživan je primenom Garsonove jednačine. Rezultati su pokazali da vreme filtracije ima najznačajniju ulogu u određivanju fluksa permeata, sa stepenom značajnosti od 50% do 83%, što je u skladu sa objavljenim naučnim rezultatima u ovoj oblasti. Sledeći faktor po važnosti relativnog uticaja na fluks permeata je prividna brzina napojne smeše, osim u slučaju modela objedinjenih rezultata gde prividna brzina vazduha ima veći stepen značajnosti. Moguće objašnjenje za ovakav rezultat je izražen negativan uticaj uduvavanja vazduha na smanjenje fluksa permeata. Prvo, uduvavanje vazduha doprinosi komprimovanijoj strukturi filtracione pogače i uticanju na smanjenje fluksa permeata usled većeg otpora proticanju. Drugo, sinergično delovanje uduvavanja vazduha i promotora turbulencije izazva intenzivne turbulencije u sistemu koje mogu dovesti do tolikog stanjivanja debljine filtracione pogače i pri tom omogućiti pojačano unutrašnje prljanje. Osim toga, koncept neuronskih mreža je pre svega model „crne kutije“ koji uprkos postojanju metoda procene uticaja parametara na izmerene veličine predviđa odnose u procesu bez razumevanja uticaja faktora i njihovih međusobnih interakcija. Detaljnija analiza ovog zaključka zahteva dodatne eksperimente koji izlaze iz opsega ove disertacije, ali takođe predstavlja dobar pravac za buduća istraživanja.

- Razvojem modela za predviđanje stacionarnog fluksa uočeno je da upotreba kombinacije promotora turbulencije i uduvavanja vazduha rezultuje porastom fluksa u stacionarnom stanju za oko 102% u odnosu na sistem sa dvofaznim tokom, odnosno oko 27% u odnosu na sistem sa promotorom turbulencije i čak oko 240% u odnosu na sistem bez promotora turbulencije. Manje vrednosti stacionarnog fluksa permeata u uslovima dvofaznog toka mogu da se objasne uticajem uduvavanja vazduha na stvaranje komprimovanije filtracione pogače zbog karakteristične specifične prostorne organizacije ćelija mikroorganizama soja *Bacillus valezensis* u strukturi filtracione pogače i nedovoljnoj efikasnosti postignutog režima proticanja da utiče na povećanje turbulencije napojne smeše i smanjenje debljine filtracione pogače, što je u skladu sa literaturnim navodima o uticaju uduvavanja vazduha na formiranje komprimovanije filtracione pogače.
- Model stacionarnog fluksa je pokazao manje greške predviđanja u odnosu na vrednosti dobijene za objedinjene podatke koji su iskorišćeni za dobijanje jedinstvenog modela neuronske mreže za simulaciju svih metoda poboljšanja fluksa. Ovakvi rezultati mogu da se objasne intenzivnijom promenom fluksa permeata u dinamičkom režimu rada mikrofiltracionog sistema koji su posledica uticaja primene metoda poboljšanja fluksa permeata za razliku od uslova u stacionarnom stanju gde je ovaj stepen promene manje intenzivan. Relativan značaj ulaznih promenljivih, kao i kod dinamičkog modela za predviđanje fluksa permeata, istraživao je primenom Garsonove jednačine. Rezultati su pokazali da prividna brzina napojne smeše ima najvažniju ulogu u određivanju fluksa permeata u stacionarnim uslovima, što je u korelaciji sa drugim istraživanjima uticaja procesnih parametara na fluks u stacionarnim uslovima.
- Upotreba postupaka kojima se utiče na promenu hidrodinamičkog režima strujanja dovodi do povećanja pada pritiska kroz membranu što predstavlja dodatni utrošak energije, a ekonomska opravdanost primene metoda poboljšanja fluksa obezbeđuje se smanjenjem specifične potrošnje energije u odnosu na sistem bez primene metode poboljšanja fluksa. Razvojem modela neuronske mreže za procenu specifične potrošnje energije uočeno je da specifična potrošnja energije sistema sa statičkim mešačem i sistema sa dvofaznim tokom pokazuje slične vrednosti, a da kombinovan postupak primene promotora turbulencije i dvofaznog toka postiže najmanji gubitak hidraulične snage od svih primenjenih metoda zbog čega se pokazao kao najefikasniji u pogledu specifične potrošnje energije. Relativan značaj ulaznih promenljivih procenjen primenom Garsonove jednačine pokazao je da prividna brzina napojne smeše ima najvažniju ulogu

u određivanju specifične potrošnje energije. Ovakav rezultat je očekivan s obzirom da povećanje protoka napojne smeše dovodi do povećanja pada pritiska u kanalu membrane što za posledicu ima gubitak hidrauličke snage, a samim tim i povećanje specifične potrošnje energije.

8. Literatura

Abbasi, M., Mohammad, R.S., Salahi, A., Mirza, B. (2012). Modeling of Membrane Fouling and Flux Decline in Microfiltration of Oily Wastewater Using Ceramic Membranes. *Chemical Engineering Communications*, 199(1); 78–93. doi:10.1080/00986445.2011.570391

Al-Abri M., Hilal N. (2008). Artificial neural network simulation of combined humic substance coagulation and membrane filtration. *Chemical Engineering Journal*, 141; 27–34. doi:10.1016/j.cej.2007.10.005

Altmann J., Rippergar S. (1997). Particle deposition and layer formation at the crossflow microfiltration. *Journal of Membrane Science*, 124; 119–128 doi:10.1016/S0376-7388(96)00235-9

Armbruster. S., Brochard, A., Lolsberga, J., Yuce, S., Wessling, M. (2019). Aerating static mixers prevent fouling. *Journal of Membrane Science*, 570–571; 537–546. doi:10.1016/j.memsci.2018.10.039

Asghari M., Dashti A., Rezakazemi M., Jokar E., Halakoei H. (2020). Application of neural networks in membrane separation. *Reviews in Chemical Engineering*, 36(2); 265–310. doi:10.1515/revce-2018-0011

Avarzaman M., Zarafshan P., Mirsaeedghazi H., Alaeddini, B. (2017). Intelligent Modeling of Permeate Flux during Membrane Clarification of Pomegranate Juice. *Nutrition and Food Sciences Research*, 4 (3); 29-38. doi: 10.18869/acadpub.nfsr.4.3.29

Aydiner C., Demir I., Yildiz, E. (2005). Modeling of flux decline in crossflow microfiltration using neural networks: the case of phosphate removal. *Journal of Membrane Science*, 248(1); 53-62. doi:0.1016/j.memsci.2004.07.036

Bagheri M., Akbari A., Mirbagheri, S.A. (2019). Advanced control of membrane fouling in filtration systems using artificial intelligence and machine learning techniques: A critical review. *Process Safety and Environmental Protection*, 123; 229–252. doi:10.1016/j.psep.2019.01.013

- Baker, R. (2004). *Membrane Technology and Application* (2nd ed.). The Atrium, Southern Gate, Chichester,, West Sussex, England: John Wiley & Sons Ltd. doi:10.1002/0470020393
- Behroozi A.H., Kasiri N., Mohammadi, T. (2019). Empirical modeling coupled with pore blocking for predicting cake formation of electric field effects on oily waste water cross-flow microfiltration, *Journal of Membrane Science*, 584; 120–136. doi:10.1016/j.memsci.2019.04.034
- Bellhouse B.J., Sobey I.J. Alani S., DeBlois, B.M. (1997). Enhanced filtration using flat membranes and standing vortex waves. *Bioseparation*, 4; 127-138. doi:10.1016/0376-7388(94)00257-Y
- Ben Hassan I., Lafforgue C., Ellero C., Ayadi A., Schmitz, P. (2013). Coupling of local visualization and numerical approach for particle microfiltration optimization. *Microsystem Technologies*, 19(3); 509-517. doi: 10.1007/s00542-013-1906-9
- Blake, N.J., I.W. Gunning, I.W., Streat, M. (1992). Prediction of steady state crossflow filtration using a force balance model. *Journal of Membrane Science*, 68 (3); 205-215. doi:10.1016/0376-7388(92)85022-B
- Bowen, WR. and Jenner, F. (1995). Theoretical descriptions of membrane filtration of colloids and fine particles: An assessment and review. *Adv. Colloid Interface Sci*, 56; 141-200. doi:10.1016/0001-8686(94)00232-2
- Cabassud, C., Laborie, S., Durand-Bourlier, L., Lainé, J.M. (2001). Air sparging in ultrafiltration hollow fibers: relationship between flux enhancement, cake characteristics and hydrodynamic parameters. *Journal of Membrane Sciences*, 181(1); 57-69. doi:10.1016/S0376-7388(00)00538-X
- Catalina M., Cot J., Celma P., Manich, A., Marsal, A. (2013). Molecular weight separation of collagen-base biomaterials by ultrafiltration. 32nd Congress of the International Union of Leather Technologists and Chemist Societies. IULTCS 2013. Istanbul. Turkey. 29-31 May 2013

- Chellam, S. (2005). Artificial neural network model for transient crossflow microfiltration of polydispersed suspensions. *Journal of Membrane Science*, 258(1-2); 35-42. doi:10.1016/j.memsci.2004.11.038
- Chen, H., Kim, A.S. (2006). Prediction of permeate flux decline in crossflow membrane filtration of colloidal suspension: a radial basis function neural network approach. *Desalination*. 192(1-3); 415–428. doi:10.1016/j.desal.2005.07.045
- Cheng, L.H., Cheng, Y.F., Chen, J. (2008). Predicting effect of interparticle interactions on permeate flux decline in CMF of colloidal suspensions: An overlapped type of local neural network. *Journal of Membrane Science*. 308(1); 54-65. doi:10.1016/j.memsci.2007.09.057
- Cheryan, M. (1986). *Ultrafiltration Handbook*. Technomic Publishing Co., Inc., Lancaster, Basel. ISBN 9781566765985
- Corbaton-Baguena, M.J., Vincent-Vela, M.C., Gozálvez-Zafrilla, J.M., Álvarez-Blanco, S., Lora-García J., Catalan-Martínez, D. (2016). Comparison between artificial neural networks and Hermia's models to assess ultrafiltration performance. *Separation and Purification Technology*, 170; 434-444. doi:10.1016/j.seppur.2016.07.007
- Curcio, S., Calabro, V., Iorio, G. (2009). Reduction and control of flux decline in cross-flow membrane processes modeled by artificial neural networks. *Journal of Membrane Science*, 286; 125–132. doi:10.1016/j.desal.2007.10.072
- Curcio, S., Iorio, G. 2013. Models of membrane reactors based on artificial neural networks and hybrid approaches. *Handbook of membrane reactors*. Chapter 16. Woodhead Publishing Limited; 569-597. doi:10.1533/9780857097330.3.569
- Da Silva, I.N., Flauzino, R.A. (2008). An approach based on neural networks for estimation and generalization of crossflow filtration processes. *Applied Soft Computing*. 8; 590–598. doi:10.1016/j.asoc.2007.03.008
- Demuth, H., Beale, M. (2004). *Neural Network Toolbox User's Guide*. Revised for Version 4. The MathWorks, Inc.

- Derradji, A.F., Bernabeu-Madico, A., Taha, S., Dorange, G. (2000). The effect of a static mixer on the ultrafiltration of a two-phase flow. *Desalination*, 128 (3); 223-230. doi:10.1016/S0011-9164(00)00037-0
- Dornier, M., Decloux, M., Trystram, G., Lebert, A. (1995). Dynamic modeling of crossflow microfiltration using neural networks. *Journal of Membrane Science*, 98; 263-273. doi:10.1016/0376-7388(94)00195-5
- Faibish, R.S., Elimelech, M., Cohen, Y.(1998). Effect of interparticle electrostatic double layer interactions on permeate flux decline in crossflow membrane filtration of colloidal suspensions: an experimental investigation. *J. Colloid Interf. Sci.*, 204(1); 77–86. doi:10.1006/jcis.1998.5563
- Ferreira, S.L.C., Bruns, R.E., Ferreira, H.S., Matos, G.D., David, J.M., Brandao, G.C., Da Silva E.G.P., Portugal, L.A., dos Reis, P.S., Souza, A.S., dos Santos, W.N.L. (2007). Box-Behnken design: An alternative for the optimization of analytical methods. *Analytica Chimica Acta*, 597(2);179-186. doi:10.1016/j.aca.2007.07.011
- Field, R.W., Wu, D., Howell, J.A., Gupta, B.B. (1995). Critical flux concept for microfiltration fouling. *Journal of Membrane Science*, 100(3); 259–272. doi:10.1016/0376-7388(94)00265-Z
- Fu, R.Q., Xu, T.W., Pan, Z.X. (2005). Modelling of the adsorption of bovine serum albumin on porous polyethylene membrane by back-propagation artificial neural network. *Journal of Membrane Science*, 251(1); 137-144. doi:10.1016/j.memsci.2004.11.007
- Garson, G.D. (1991). Interpreting Neural Network Connection Weights. *Artificial Intelligence Expert*, 6(4); 46–51
- Ghandehari, S., Montazer-Rahmati, M.M., Asghari, M. (2011). A comparison between semi-theoretical and empirical modeling of cross-flow microfiltration using ANN. *Desalination*, 277 (1); 348-355. doi:10.1016/j.desal.2011.04.057
- Ghandehari, S., Montazer-Rahmati, M.M., Asghari, M. (2013). Modeling the Flux Decline during Protein Microfiltration: A Comparison between Feed-Forward Back

Propagation and Radial Basis Function Neural Networks. *Separation Science and Technology*, 48; 1324–1330. doi:10.1080/01496395.2012.736914

Guadix, A., Zapata, J.E., Almecija, M.C., Guadix, E.M. (2010). Predicting the flux decline in milk cross-flow ceramic ultrafiltration by artificial neural networks. *Desalination*, 250; 1118–1120. doi:10.1016/j.desal.2009.09.121

Guan, K., Liu, Y., Yin, X., Zhu, W., Chu, Y., Peng, C., Lv, M., Sun, Q., Rao, P., Wu, J. (2017). Influence of operation conditions on cake structure in dead-end membrane filtration: Monte Carlo simulations and a force model. *Chemical Engineering Research and Design*, 124; 124–133. doi:10.1016/j.cherd.2017.06.008

Hamachi, M., Cabassud, M., Davin, A., Peuchot, M. (1999). Dynamic modelling of crossflow microfiltration of bentonite suspension using recurrent neural networks. *Chemical Engineering and Processing: Process Intensification*, 38(3); 203-210. doi:10.1016/S0255-2701(99)00004-5

Hasan, A., Peluso, C.R., Hull, T.S., Fieschko, J., Chatterjee, S.G. (2013). A surface renewal model of cross-flow microfiltration. *Brazilian Journal of Chemical Engineering*, 30(1); 167–186. doi:10.1590/S0104-66322013000100019

Hashemi, F., Rowshanzamira, S., Rezakazemi, M. (2012). CFD simulation of PEM fuel cell performance: Effect of straight and serpentine flow fields. *Mathematical and Computer Modelling*, 55; 1540–1557. doi:10.1016/j.mcm.2011.10.047

Hermia, J. (1985). Blocking Filtration. Application to Non-Newtonian Fluids. *Mathematical models and design methods in solid-liquid separation*, NATO ASI series, 88; 83-84; Springer. doi:10.1007/978-94-009-5091-7_5

Hilal, N., Ogunbiyi, O.O., Al-Abri, M. (2008). Neural network modeling for separation of bentonite in tubular ceramic membranes. *Desalination*, 228(1); 175-182. doi:10.1016/j.desal.2007.10.006

Homem, N.C., de Camargo L., Beluci, N., Amorim, S., Reis, R., Vieira, A.M.S., Vieira, M.F., Amorim, M.T.P. (2019). Surface modification of a polyethersulfone microfiltration membrane with graphene oxide for reactive dyes removal. *Applied Surface Science*, 486; 499-507. doi:10.1016/j.apsusc.2019.04.276

- Hoskins, J.C., Himmelblau, D.M. (1988). Artificial neural network models of knowledge representation in chemical engineering. *Comput. Chem. Eng.*, 12; 881–890. doi:10.1016/0098-1354(88)87015-7
- Hossain, N., Rahman, M. (2014). Antagonistic activity of antibiotic producing *Streptomyces* sp. against fish and human pathogenic bacteria. *Brazilian Archives of Biology and Technology*, 57; 233-237. doi:10.1590/S1516-89132014000200011
- Hwang, K.J., Cheng, Y.H., Tung, K.L. (2003). Modeling of Cross-Flow Microfiltration of Fine Particle/Macromolecule Binary Suspension. *Journal of chemical engineering of Japan*, 36(12); 1488-1497. doi:10.1252/jcej.36.1488
- Hwang, K.-J., Hsu, C.-E. (2009). Effect of gas–liquid flow pattern on air-sparged cross-flow microfiltration of yeast suspension. *Chemical Engineering Journal*, 151(1–3), 160-167. doi:10.1016/j.cej.2009.02.009
- Hwang, K.-J., Chen, L. (2010). Effect of air-sparging on the cross-flow microfiltration of microbe/protein bio-suspension. *Journal of the Taiwan Institute of Chemical Engineers*, 41, 564–569. doi:10.1016/j.jtice.2009.12.005
- Hwang, T.M., Choi, Y., Nam, S.H., Lee, S., Oh, H., Hyun, K., Choung, Y.K. (2010a). Prediction of membrane fouling rate by neural network modeling. *Desalination and Water Treatment*, 15; 134–140. doi:10.5004/dwt.2010.1677
- Hwang, K.J., Ku, C.Y. (2014). Model development for estimating microfiltration performance of bio-ethanol fermentation broth. *Journal of the Taiwan Institute of Chemical Engineers*, 45(3); 1233-1240. doi:10.1016/j.jtice.2014.01.001
- Ibeid, S., Elektorowicz, M., Oleszkiewicz, J.A. (2013). Novel electrokinetic approach reduces membrane fouling. *Water Research*, 47(16); 6358–6366. doi:10.1016/j.watres.2013.08.007
- Ikonić, B., Zavargo, Z., Šereš, Z., Gyura, J., Jokić, A. (2012). Flux Improvement during Cross-flow Microfiltration of Wheat Starch Suspension using Turbulence Promoter. *Separation Science and Technology*, 47; 972–982. doi:10.1080/01496395.2011.640379

Iritani, E., Katagiri, N., Ishikawa, Y., Cao, D.Q. (2014). Cake formation and particle rejection in microfiltration of binary mixtures of particles with two different sizes. *Separation and Purification Technology*, 123; 214–220. doi:10.1016/j.seppur.2013.12.033

Jalilvand, Z., Ashtiani, F.Z., Fouladitajar, A., Rezaei, H. (2014). Computational fluid dynamics modeling and experimental study of continuous and pulsatile flow in flat sheet microfiltration membranes. *Journal of Membrane Science*, 450; 207–214. doi:10.1016/j.memsci.2013.09.008

Javadi, N., Ashtiani, F.Z., Fouladitajar, A., Zenooz, A.M. (2014). Experimental studies and statistical analysis of membrane fouling behavior and performance in microfiltration of microalgae by a gas sparging assisted process. *Bioresource Technology*, 162; 350-357. doi:10.1016/j.biortech.2014.03.160

Jokić, A., Zavargo, Z., Šereš, Z., Tekić, M. (2010). The effect of turbulence promoter on cross-flow microfiltration of yeast suspensions: A response surface methodology approach. *Journal of Membrane Science*, 350; 269–278. doi:10.1016/j.memsci.2009.12.037

Jokić, A. 2012. *Primena postupka odzivne površine u modelovanju mikrofiltracije*. Beograd: Zadužbina Andrejević, Beograd. ISBN 978-86-525-0038-3

Jokić A., Šereš L., Milović N., Šereš Z., Maravić N., Šaranović Ž., Dokić Lj. 2018. Modelling of starch industry wastewater microfiltration parameters by neural network. *Membrane Water Treatment*, 9(1); 115-121. doi: 10.12989/mwt.2018.9.2.115

Karray, F., De Silva, C. (2004). *Soft Computing and Intelligent Systems Design*. Pearson Education Limited, England. ISBN: 0321116178

Khayet, M., Cojocaru, C. (2013). Artificial neural network model for desalination by sweeping gas membrane distillation. *Desalination*, 308; 102–110. doi:10.1016/j.desal.2012.06.023.

Kim, J.O., Somiya, I. (2003). Innovative fouling control by intermittent back-ozonation in metal membrane micro filtration system. *Water Science and Technology: Water Supply*, 3(3); 55–61. doi:10.2166/ws.2003.0008

- Knutsen, J.S., Davis, R.H. (2006). Deposition of foulant particles during tangential flow filtration. *Journal of Membrane Science*, 271; 101–113. doi:10.1016/j.memsci.2005.06.060
- Koonani, H., Amirinejad, M. (2019). Combined Three Mechanisms Models for Membrane Fouling during Microfiltration. *Journal of Membrane Science and Research*, 5; 274-282. doi:10.22079/JMSR.2019.95781.1224
- Krstić, D., Rađenović, R., Carić, M., Milanović, S., Tekić, M. (2002). The effect of turbulence promoter on cross-flow microfiltration of skim milk. *Journal of Membrane Science*, 208; 303–314. doi:10.1016/S0376-7388(02)00308-3
- Krstić, D., Tekić, M., Carić, M., Milanović S., (2004). Static turbulence promoter in cross-flow microfiltration of skim milk. *Desalination*, 163; 297-3097. doi:10.1016/S0011-9164(04)90203-2
- Krstić, D.M., Hoflinger, W., Koris, A.K., Gyula N. Vatai, G.N. (2007). Energy-saving potential of cross-flow ultrafiltration with inserted static mixer: Application to an oil-in-water emulsion. *Separation and Purification Technology*, 57 (1); 134–139. doi:10.1016/j.seppur.2007.03.023
- Li, H.Y., Bertram, C.H., Wiley, D.E. (1998). Mechanisms by Which Pulsatile Flow Affects Cross-Flow Microfiltration. *AIChE Journal*, 44 (9). doi:10.1002/aic.690440903
- Li, M., Zhao, Y., Zhou, S., Xing, W., Wong, F.-S. (2007). Resistance analysis for ceramic membrane microfiltration of raw soy sauce. *Journal of Membrane Science*, 299; 122–129. doi:10.1016/j.memsci.2007.04.033
- Lipnizki, F., Tragardh, G. (2001). Modeling of peevaporation: Models to analyze and predict the mass transport in peevaporation. *Separation & Purification Reviews*, 30(1); 49–125. doi:10.1081/SPM-100102985
- Liu, Q.F., Kim, S.H, Lee, S. (2009). Prediction of microfiltration membrane fouling using artificial neural network models. *Separation and Purification Technology*, 70; 96–102. doi:10.1016/j.seppur.2009.08.017

- Liu, Y., He, G., Li, B., Hu, Z., Ju, J. (2012). A comparison of cake properties in traditional and turbulence promoter assisted microfiltration of particulate suspensions. *Water Research*, 46(8); 2535–2544. doi:10.1016/j.watres.2012.02.002
- Liu, Y., He, G., Tana, M., Nie, F., Li, B. (2014). Artificial neural network model for turbulence promoter-assisted crossflow microfiltration of particulate suspensions. *Desalination*, 338; 57–64 doi:10.1016/j.desal.2014.01.015.
- Liu, C., Hu, G., Jiang, X., Sun, J. (2015). Inertial focusing of spherical particles in rectangular microchannels over a wide range of Reynolds numbers. *Lab on a Chip*, 15; 1168-1177. doi:10.1039/C4LC01216J
- Luis, P., Van der Bruggen, B. (2015). *Pervaporation modeling: state of the art and future trends*. Chp. 4. Pervaporation, Vapour Permeation and Membrane Distillation. Principles and Applications Woodhead Publishing Series in Energy, 87-106. doi:10.1016/B978-1-78242-246-4.00004-0
- Madaeni, S.S., Hasankiadeh, N.T., Tavakolian, H. R. (2012). Modeling and optimization od membrane chemical cleaning by artifical neural network, fuzzy logic and genetic algorithm. *Chemical Engineering Communications*, 199(3); 399-416. doi:10.1080/00986445.2011.592450
- Mahenc, J., Lafaille, J. P., Sanchez, V. (1986). Estimation of the Performance of Hollow Fiber Ultrafiltration Modules. *International chemical engineering*, 26 (4); 660-670
- Marković, Z., Pronić-Rančić, O., Marković, V. (2015). *Primena veštačkih neuronskih mreža za razvoj modela RF i mikrotalasnih tranzistora*. XXXII Simpozijum o novim tehnologijama u poštanskim i telekomunikacionom saobraćaju-PosTel, Beograd 1-2 Decembar
- Marzban, R., Saberi, F., Shirazi, M.M.A. (2016). Microfiltration and ultrafiltration of *Bacillus thuringiensis* fermetation broth: membrane performance and sporecrystall recovery approach. *Brazilian Journal of Chemical Engineering*, 33(04); 783 – 791. doi:10.1590/0104-6632.20160334s20140215

- Milenković, S. 1997. *Veštačke neuronske mreže*. Zadužbina Andrejević. Beograd ISBN: 86-7244-046-3.
- Miljković, Z., Aleksendrić, D. (2018). *Veštačke neuronske mreže*. 2izd. Beograd. Mašinski fakultet Univerziteta u Beogradu. ISBN 978-86-7083-685-3
- Mirbagheri, S.A., Bagheri, M., Bagheri Z., Kamarkhani, A.M. (2015). Evaluation and prediction of membrane fouling in a submerged membrane bioreactor with simultaneous upward and downward aeration using artificial neural network-genetic algorithm. *Process Safety and Environmental Protection*, 96; 111–124. doi:10.1016/j.psep.2015.03.015
- Mondor, M., Girard, B., Moresoli, C. (2000). Modeling flux behaviour for membrane filtration of apple juice. *Food Research International*, 33; 539-548. doi:10.1016/S0963-9969(00)00089-2
- Mota, M., Teixeira, J.A., Yelshin, A. (2002). Influence of cell-shape on the cake resistance in dead-end and crossflow filtrations. *Separation and Purification Technology*, 27; 137–144. doi:10.1016/S1383-5866(01)00202-7
- Mulder, M. (1996). *Basic Principles of Membrane Technology*. The Netherlands: Kluwer Academic Publishers. ISBN: 978-94-009-1766-8
- Nakashima, T., Shimizu, M. (1989). Microfiltration of Oil in Water Emulsion by Porous Glass Membran. *Kagaku Kogaku Ronbunshu*, 15 (3); 645-651
- Nandi, B.K., Moparthi, A., Uppaluri, R., Purkait, M.K. (2010). Treatment of oily wastewater using low cost ceramic membrane: Comparative assessment of pore blocking and artificial neural network models. *Chemical Engineering Research and Design*, 88; 881–892. doi:10.1016/j.cherd.2009.12.005
- Ni Mhurichu, J., Foley, G., Havel, J. (2006). Dead-end filtration of yeast suspensions: Correlating specific resistance and flux data using artificial neural networks. *Journal of Membrane Science*, 281; 325–333. doi:10.1016/j.memsci.2006.03.043

- Ni Mhurichu, J., Foley, G., Havel, J. (2010). Modeling process dynamic using novel neural network architecture: Application to stirred cell microfiltration. *Chemical Engineering Communications*, 197(8); 1152-1162. doi:10.1080/00986440903359442
- Nourbakhsh, H., Emam-Djomeh, Z., Omid, M., Mirsaeedghazi, H., Moini, S. (2014). Prediction of red plum juice permeate flux during membrane processing with ANN optimized using RSM. *Computers and Electronics in Agriculture*, 102; 1-9. <https://doi.org/10.1016/j.compag.2013.12.017>
- Nunes, S., Peinemann, K-V. (2006). *Membrane Technology in the Chemical Industry*. 2nd Edition. Wiley-VCH, England. ISBN:9783527600380
- Ogunbiyi, O.O., Hilal, N., Miles, N.J. (2007). Comparison of different pitch lengths on static promoters for flux enhancement in tubular ceramic membrane. *Separation Science and Technology*, 42(1); 19. doi:10.1080/01496390701401576
- Olden, J.D., Jackson, A.D. (2002). Illuminating the “black box”: a randomization approach for understanding variable contributions in artificial neural networks. *Ecological Modelling*, 154 (1–2); 135-150. doi:10.1016/S0304-3800(02)00064-9
- Olden, J. D., Joy, M.K., Death, R.G. (2004). An accurate comparison of methods for quantifying variable importance in artificial neural networks using simulated data. *Ecological Modelling*, 178; 389–397. doi:10.1016/j.ecolmodel.2004.03.013
- Paixao, R.M., Da Silva, L.H.B.R., Reck, I.M., Vieira, M.F., Bergamasco, R., Vieira, A. M.S. (2019). Deposition of graphene nanoparticles associated with tannic acid in microfiltration membrane for removal of food colouring. *Environmental Technology*, 1–23. doi:10.1080/09593330.2019.1627426
- Pajčin, I. (2019). Optimizacija uslova umnožavanja i primarnog izdvajanja biomase *Bacillus* sp. za primenu u fitomedicini. Doktorska disertacija, Tehnološki fakultet Novi Sad, Univerzitet u Novom Sadu, Srbija
- Pal, S., Bharihoke, R., Chakraborty, S., Ghatak, S.K., De, S., Das Gupta, S. (2008). An experimental and theoretical analysis of turbulence promoter assisted ultrafiltration of synthetic fruit juice. *Separation and Purification Technology*, 62(3); 659–667. doi:10.1016/j.seppur.2008.03.010

Pan, Y., Wang, W., Wang, W., Wanga, T. (2015). Prediction of particle deposition and layer growth in the preparation of a dynamic membrane with cross-flow microfiltration. *RSC Advances*, 108 (5); 89015-89024. doi:10.1039/C5RA14572D

Paunović, R., Omorjan, R. (2014). *Osnove inženjerske statistike*. Novi Sad. Tehnološki fakultet Univerziteta u Novom Sadu.

Piron, E., Latriille, E., Rene, F. (1997). Application of artificial neural networks for crossflow microfiltration modelling: “black-box” and semi-physical approaches. *Computers & Chemical Engineering*, 21(9);1021-1030. doi:10.1016/S0098-1354(96)00332-8

Pospišil, P., Wakeman, R.J., Hodgson, I.O.A., Mikulanek, P. (2004). Shear stress-based modelling of steady state permeate flux in microfiltration enhanced by two-phase flows. *Chemical Engineering Journal*, 97(2-3); 257-263. doi:10.1016/j.cej.2003.05.001

Rezaei, H., Ashtiani, F.Z., Fouladitajar, A. (2014). Fouling behavior and performance of microfiltration membranes for whey treatment in steady and unsteady-state conditions. *Brazilian Journal of Chemical Engineering*, 31(2); 503 – 518. doi:10.1590/0104-6632.20140312s00002521

Rezakazemi, M., Ghafarinazari, A., Shirazian, S., Khoshsima, A. (2012). Numerical modeling and optimization of wastewater treatment using porous polymeric membranes. *Polymer Engineering & Science*, 53(6); 1272–1278. doi:10.1002/pen.23375

Riesmeier, B., Kroner, K. H., Kula, M. R. (1989). Tangential filtration of microbial suspensions: filtration resistances and model development. *Journal of Biotechnology*, 12(2); 153-171. doi:10.1016/0168-1656(89)90013-8

Ripperger, S., Altmann, J. (2002). Crossflow microfiltration – state of the art. *Separation and Purification Technology*, 26(1); 19–31. doi:10.1016/S1383-5866(01)00113-7

Sahoo, G., Ray, C. (2006). Predicting flux decline in crossflow membranes using artificial neural networks and genetic algorithms. *Journal of Membrane Science*, 283; 147–157. doi:10.1016/j.memsci.2006.06.019

Salas-Leyva, M., Mounier, J., Valence, F., Coton, M., Thierry, A., Coton, E. (2017). Antifungal Microbial Agents for Food Biopreservation-A Review. *Microorganisms*, 5 (37); 1-35. doi:10.3390/microorganisms5030037.

Samuelsson, G., Dejmek, P., Tragardh, G., Paulsson, M. (1997). Minimizing whey protein retention in cross-flow microfiltration of skim milk. *International Dairy Journal*, 7; 237-242. doi:10.1016/S0958-6946(97)00009-5

Sanaei, P., Cummings, L.J. (2017). Flow and fouling in membrane filters: effects of membrane morphology. *Journal of Fluid Mechanics*, 818; 744-771. doi:10.1017/jfm.2017.102

Sarkar, B., Sengupta, A., De, S., Das Gupta, S. (2009). Prediction of permeate flux during electric field enhanced cross-flow ultrafiltration—A neural network approach. *Separation and Purification Technology*, 65; 260–268. doi:10.1016/j.seppur.2008.10.032

Shahriari, S., Hakimzadeh, V., Shahidi, M. (2017). Modeling the efficiency of microfiltration process in reducing the hardness, improvement the non-sugar component rejection and purity of raw sugar beet juice. *Ukrainian Food Journal*, 6 (4); 648-660. doi: 10.24263/2304-974X-2017-6-4-6

Shishido, M., Sawada, S., Goto, C. (1988). Application of Crossflow Microfiltration to the Separation and Concentration of a Ferric Hydroxide Suspension. 391-392

Soleimani, R., Shoushtari, N.A., Mirza, B., Salahi, A. (2013). Experimental investigation, modeling and optimization of membrane separation using artificial neural network and multi-objective optimization using genetic algorithm. *Chemical Engineering Research and Design*, 91(5); 883-903. doi:10.1016/j.cherd.2012.08.004

Song, L. (1998). Flux decline in crossflow microfiltration and ultrafiltration: mechanisms and modeling of membrane fouling. *Journal of Membrane Science*, 139;183-200. doi:10.1016/S0376-7388(97)00263-9

Šećerov-Sokolović, R., Sokolović, S. (2002). *Inženjerstvo u zaštiti okoline*. Novi Sad: Tehnološki Fakultet. Univerzitet u Novom Sadu. ISBN: 628.316.12(0.75)

Šereš, Z., Dokić, L., Pajin, B., Šoronja-Simović, D., Šubarić, D., Babić, J., Fišteš, A. (2012). Influence of the operating parameters on the flux during microfiltration of the steepwater in the starch industry. *Acta Periodica Technologica*, 43; 225-235. doi: 10.2298/APT1243225S

Šereš, L., Dokić, L., Ikonić, B., Šoronja-Simović, D., Đorđević, M., Šaranović, Ž., Maravić, N. (2018). Data-driven Modelling of Microfiltration Process with Embedded Static Mixer for Steepwater from Corn Starch Industry. *Periodica Polytechnica Chemical Engineering*, 62 (1); 114-122. doi:10.3311/PPch.10400

Tiwari, P., Antal, S.P., Podowski, M.Z. (2009). Modeling shear-induced diffusion force in particulate flows. *Computers & Fluids*, 38; 727–737. doi:/10.1016/j.compfluid.2008.09.007

Torrecilla, J.S., Otero, L., Guignon, B., Sanz, P.D., Ramos, A. (2006). *Modelling of high-pressure treatments of foods by an Artificial Neural Network*. CHISA 2006. 17th International Congress of Chemical and Process Engineering; 1-12

Urošević, T., Povrenović, D., Vukosavljević, P., Urošević, I. (2018). Mikrofiltracija sa periodičnim povratnim ispiranjem kao alternativna tehnika za povećanje fluksa permeata. *Hemijska industrija*, 72 (2); 59–68. doi:10.2298/HEMIND170814021U

Vatai, G.N., Darko M. Krstić, D.M., Hoflinger, W., Koris, A.K., Tekić, M.N. (2007). Combining air sparging and the use of a static mixer in cross-flow ultrafiltration of oil/water emulsion. *Desalination*, 204 (1-3); 255–264 doi:0.1016/j.desal.2006.02.034

Vivier, J., Mehabilia, A. (2012). A New Artificial Network Approach for Membrane Filtration Simulation. *Chemical and Biochemical Engineering Quarterly*, 26(3); 241–248

Vyas, H.K., Bennett, R.J., Marshall, A.D. (2000). Influence of operating conditions on membrane fouling in crossflow microfiltration of particulate suspensions, *International Dairy Journal*, 10 (7); 477-487. doi:10.1016/S0958-6946(00)00058-3

Wakeman, R.J., Williams, C.J. (2002). Additional techniques to improve microfiltration. *Separation and Purification Technology*, 26; 3–18. doi:10.1016/S1383-5866(01)00112-5

- Wang, Z., Cui, Y., Wu, W., Ji, S., Yao, J., Zhang, H., Zhao, X. (2009). The convective model of flux prediction in a hollow-fiber module for a steady-state cross-flow microfiltration system. *Desalination*, 238 (1-3); 192-209. doi:10.1016/j.desal.2008.02.013
- Wei, A., Zeng, G., Huang, G., Liang, I. J., Li, X. (2009). Modeling of a permeate flux of cross-flow membrane filtration of colloidal suspensions: A wavelet network approach. *Int. J. Environ. Sci. Tech.* 6(3); 395-406. doi:10.1007/BF03326078
- Winiczenko, R., Gornicki, K., Kaleta, A., Mankowska, M.J. (2018). Optimisation of ANN topology for predicting the rehydrated apple cubes colour change using RSM and GA. *Neural Computing and Applications*, 30; 1795-1809. doi:10.1007/s00521-016-2801-y
- Youravong, W., Li, Z., Laorko, A. (2010). Influence of gas sparging on clarification of pineapple wine by microfiltration. *Journal of Food Engineering*, 96; 427-432. doi:10.1016/j.jfoodeng.2009.08.021
- Zydney, A.L., Colton, C.K. (1986). A concentration polarization model for the filtrate flux in cross-flow microfiltration of particulate suspensions. *Chem. Eng. Commun.*, 47; 1-21. doi:10.1080/00986448608911751

PRILOG 1.

Tabela P1.1 Uticaj broja neurona u skrivenom sloju neuronske mreže na srednju kvadratnu grešku (MSE) podataka mikrofiltracije kultivacione tečnosti *Streptomyces hygroscopicus* bez prisustva statičkog mešača (NSM) u uslovima ugušćivanja

	Model									
	trainlm		trainbr		trainrp		trainseg		trainoss	
	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig
1	1,56E-02	1,56E-02	1,57E-02	1,58E-02	2,20E-02	2,21E-02	1,65E-02	1,72E-02	1,88E-02	2,21E-02
2	9,46E-03	9,89E-03	1,01E-02	1,02E-02	1,69E-02	1,58E-02	1,35E-02	1,58E-02	1,68E-02	2,24E-02
3	5,82E-03	4,56E-03	4,73E-03	5,26E-03	1,41E-02	1,65E-02	1,28E-02	1,58E-02	1,63E-02	2,30E-02
4	3,32E-03	2,46E-03	2,97E-03	3,04E-03	1,41E-02	1,48E-02	1,24E-02	1,49E-02	1,75E-02	2,12E-02
5	2,13E-03	1,48E-03	1,79E-03	1,52E-03	1,46E-02	1,51E-02	1,19E-02	1,41E-02	1,77E-02	2,07E-02
6	9,96E-04	7,20E-04	1,24E-03	9,41E-04	1,30E-02	1,48E-02	1,17E-02	1,67E-02	1,84E-02	2,13E-02
7	8,19E-04	7,76E-04	8,01E-04	9,20E-04	1,31E-02	1,72E-02	1,23E-02	1,73E-02	1,84E-02	2,19E-02
8	3,53E-04	3,75E-04	6,99E-04	6,43E-04	1,28E-02	1,81E-02	1,15E-02	1,66E-02	1,86E-02	2,07E-02
9	4,26E-04	2,72E-04	5,42E-04	6,44E-04	1,30E-02	1,86E-02	1,15E-02	1,87E-02	2,06E-02	2,15E-02
10	2,93E-04	2,93E-04	5,57E-04	4,52E-04	1,32E-02	1,73E-02	1,07E-02	1,88E-02	2,10E-02	2,04E-02
11	2,17E-04	2,22E-04	5,44E-04	4,78E-04	1,40E-02	2,14E-02	1,29E-02	1,80E-02	2,08E-02	2,19E-02
12	5,83E-04	3,01E-04	5,99E-04	3,84E-04	1,37E-02	2,10E-02	1,32E-02	1,81E-02	2,07E-02	2,11E-02
13	4,04E-04	1,75E-04	3,33E-04	4,58E-04	1,39E-02	2,00E-02	1,20E-02	1,91E-02	2,25E-02	2,23E-02
14	2,70E-04	1,51E-04	3,20E-04	8,61E-04	1,52E-02	2,18E-02	1,20E-02	1,81E-02	2,26E-02	2,07E-02
15	1,48E-04	6,31E-05	2,84E-04	4,09E-04	1,58E-02	2,24E-02	1,25E-02	2,06E-02	2,26E-02	2,24E-02

Tabela P1.2 Uticaj broja neurona u skrivenom sloju neuronske mreže na koeficijent determinacije (R^2) podataka mikrofiltracije kultivacione tečnosti *Streptomyces hygroscopicus* bez prisustva statičkog mešača (NSM) u uslovima ugušćivanja

	Model									
	trainlm		trainbr		trainrp		trainseg		trainoss	
	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig
1	0,81419	0,81635	0,81059	0,81268	0,70256	0,70954	0,78783	0,77772	0,75861	0,69231
2	0,88590	0,87989	0,87837	0,87727	0,78346	0,80251	0,83566	0,79737	0,78577	0,67990
3	0,95172	0,94122	0,94247	0,93591	0,82717	0,78692	0,83647	0,79144	0,79519	0,67215
4	0,98085	0,96770	0,96228	0,96218	0,81813	0,81134	0,84325	0,80485	0,77526	0,70975
5	0,99290	0,97889	0,97720	0,97939	0,81122	0,80095	0,85184	0,82009	0,75556	0,72134
6	0,99536	0,98988	0,98290	0,98772	0,83637	0,80574	0,85067	0,77975	0,74117	0,70372
7	0,99676	0,98668	0,98903	0,98731	0,83432	0,76285	0,84018	0,76354	0,75094	0,69645
8	0,99477	0,99352	0,98917	0,99096	0,83797	0,74277	0,85253	0,78428	0,74803	0,72001
9	0,99245	0,99580	0,99215	0,99111	0,83089	0,73410	0,84958	0,73694	0,69685	0,70259
10	0,99040	0,99515	0,99162	0,99343	0,82846	0,75887	0,85383	0,74279	0,69144	0,72384
11	0,99087	0,99641	0,99228	0,99315	0,81482	0,68269	0,82511	0,75535	0,69295	0,69357
12	0,99076	0,99468	0,99122	0,99318	0,81770	0,68831	0,81212	0,74357	0,69552	0,71036
13	0,99018	0,99730	0,99524	0,99303	0,81429	0,70554	0,84037	0,73172	0,66307	0,68934
14	0,98489	0,99749	0,99535	0,98736	0,79020	0,67424	0,83696	0,73960	0,66102	0,71987
15	0,98486	0,99909	0,99545	0,99369	0,77966	0,65860	0,83637	0,70475	0,66258	0,68444

Tabela P1.3 Uticaj broja neurona u skrivenom sloju neuronske mreže na srednju kvadratnu grešku (MSE) podataka mikrofiltracije kultivacione tečnosti *Streptomyces hygroscopicus* u prisustvu statičkog mešača (SM) u uslovima ugušćivanja

	Model									
	trainlm		trainbr		trainrp		trainscg		trainoss	
	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig
1	4,47E-03	4,47E-03	4,58E-03	5,68E-02	5,72E-03	2,59E-02	5,26E-03	5,42E-03	6,04E-03	6,14E-03
2	2,15E-03	2,12E-03	2,04E-03	5,68E-02	5,57E-03	9,79E-03	4,01E-03	4,54E-03	5,00E-03	4,90E-03
3	4,92E-04	4,65E-04	5,02E-04	5,68E-02	4,97E-03	3,72E-03	2,47E-03	4,25E-03	4,67E-03	5,47E-03
4	2,64E-04	2,35E-04	2,23E-04	5,68E-02	5,11E-03	3,08E-03	2,14E-03	4,13E-03	4,81E-03	4,91E-03
5	1,73E-04	1,78E-04	2,16E-04	5,68E-02	4,96E-03	2,59E-03	2,44E-03	4,27E-03	5,39E-03	4,92E-03
6	1,28E-04	1,50E-04	1,56E-04	5,68E-02	4,26E-03	2,16E-03	1,82E-03	3,76E-03	5,15E-03	4,90E-03
7	1,08E-04	1,01E-04	1,48E-04	5,68E-02	4,42E-03	2,11E-03	1,88E-03	4,76E-03	5,02E-03	5,17E-03
8	7,61E-05	7,43E-05	1,31E-04	5,68E-02	4,27E-03	1,57E-03	2,57E-03	4,36E-03	5,22E-03	5,49E-03
9	8,00E-05	8,16E-05	1,23E-04	5,68E-02	3,73E-03	1,65E-03	2,38E-03	4,58E-03	4,53E-03	5,28E-03
10	6,22E-05	6,68E-05	1,10E-04	5,68E-02	3,16E-03	1,33E-03	2,35E-03	4,55E-03	4,92E-03	5,56E-03
11	5,78E-05	6,21E-05	9,83E-05	5,68E-02	4,09E-03	1,26E-03	2,53E-03	4,40E-03	5,33E-03	5,56E-03
12	5,12E-05	5,84E-05	9,57E-05	5,68E-02	3,48E-03	8,75E-04	1,89E-03	5,19E-03	5,22E-03	6,11E-03
13	4,63E-05	5,29E-05	9,49E-05	5,68E-02	3,47E-03	1,00E-03	3,03E-03	4,34E-03	5,45E-03	5,85E-03
14	4,82E-05	5,21E-05	1,11E-04	5,68E-02	3,92E-03	1,07E-03	2,86E-03	5,22E-03	5,49E-03	6,12E-03
15	4,33E-05	5,25E-05	1,02E-04	5,68E-02	3,51E-03	1,38E-03	3,15E-03	5,11E-03	5,40E-03	5,51E-03

Tabela P1.4 Uticaj broja neurona u skrivenom sloju neuronske mreže na koeficijent determinacije (R^2) podataka mikrofiltracije kultivacione tečnosti *Streptomyces hygroscopicus* u prisustvu statičkog mešača (SM) u uslovima ugušćivanja

	Model									
	trainlm		trainbr		trainrp		trainscg		trainoss	
	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig
1	0,95655	0,95764	0,95430	0,88443	0,94027	0,95108	0,94313	0,94449	0,93713	0,93794
2	0,98093	0,97782	0,98200	0,89570	0,94058	0,95507	0,95704	0,95021	0,94658	0,95068
3	0,99532	0,99091	0,99494	0,86935	0,94568	0,96053	0,97145	0,95297	0,94982	0,94310
4	0,99768	0,99374	0,99764	0,86485	0,94546	0,96985	0,97349	0,95400	0,94691	0,94823
5	0,99836	0,99566	0,99780	0,87223	0,94613	0,97203	0,96991	0,95058	0,94144	0,94745
6	0,99852	0,99635	0,99858	0,88525	0,95281	0,97617	0,97749	0,95790	0,94376	0,94929
7	0,99917	0,99595	0,99858	0,86071	0,95139	0,98019	0,97594	0,94560	0,94510	0,94435
8	0,99894	0,99598	0,99856	0,85879	0,95270	0,98192	0,96681	0,95025	0,94362	0,94224
9	0,99929	0,99667	0,99887	0,85815	0,95946	0,98133	0,97008	0,94940	0,95052	0,94485
10	0,99941	0,99647	0,99892	0,79699	0,96537	0,98608	0,97036	0,94719	0,94708	0,94028
11	0,99947	0,99659	0,99907	0,80680	0,95679	0,98589	0,96924	0,94990	0,94319	0,94141
12	0,99949	0,99677	0,99912	0,84786	0,96189	0,99049	0,97630	0,94293	0,94428	0,93660
13	0,99953	0,99775	0,99909	0,83394	0,96276	0,98824	0,96321	0,95051	0,94233	0,93921
14	0,99956	0,99809	0,99887	0,86055	0,95782	0,98890	0,96722	0,94177	0,94128	0,93564
15	0,99955	0,99792	0,99902	0,84821	0,96165	0,98430	0,96196	0,94210	0,94179	0,94160

Tabela P1.5 Uticaj broja neurona u skrivenom sloju neuronske mreže na srednju kvadratnu grešku (MSE) objedinjenih podataka mikrofiltracije kultivacione tečnosti *Streptomyces hygroscopicus* sa i bez prisustva statičkog mešača (SM i NSM) u uslovima ugušćivanja

	Model									
	trainlm		trainbr		trainrp		trainscg		trainoss	
	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig
1	8,37E-03	8,72E-03	8,37E-03	8,37E-03	1,21E-02	1,12E-02	8,75E-03	9,06E-03	9,65E-03	1,31E-02
2	5,56E-03	5,32E-03	5,22E-03	5,32E-03	9,37E-03	8,40E-03	7,71E-03	8,68E-03	8,93E-03	1,09E-02
3	3,54E-03	3,57E-03	3,61E-03	3,42E-03	7,76E-03	7,32E-03	6,84E-03	7,53E-03	8,38E-03	9,42E-03
4	2,11E-03	2,03E-03	2,13E-03	2,16E-03	7,55E-03	6,02E-03	6,24E-03	7,07E-03	7,79E-03	9,07E-03
5	1,26E-03	1,31E-03	1,41E-03	1,48E-03	6,24E-03	5,14E-03	6,27E-03	7,07E-03	7,50E-03	8,96E-03
6	9,26E-04	8,28E-04	9,99E-04	9,75E-04	5,87E-03	4,82E-03	6,53E-03	6,88E-03	7,68E-03	8,99E-03
7	8,72E-04	6,42E-04	1,10E-03	8,62E-04	4,78E-03	4,87E-03	6,44E-03	7,27E-03	7,62E-03	9,13E-03
8	6,08E-04	9,27E-04	1,01E-03	7,03E-04	5,04E-03	4,18E-03	6,18E-03	7,25E-03	7,71E-03	9,12E-03
9	4,73E-04	5,63E-04	7,93E-04	6,14E-04	4,83E-03	4,64E-03	6,31E-03	8,27E-03	7,12E-03	8,96E-03
10	4,80E-04	5,62E-04	7,74E-04	5,14E-04	4,75E-03	4,04E-03	6,01E-03	7,58E-03	7,56E-03	8,94E-03
11	3,71E-04	5,82E-04	7,26E-04	4,13E-04	4,93E-03	3,90E-03	6,01E-03	7,94E-03	7,55E-03	9,05E-03
12	3,71E-04	5,13E-04	5,96E-04	3,57E-04	4,89E-03	3,87E-03	6,29E-03	7,80E-03	7,32E-03	9,41E-03
13	3,21E-04	5,29E-04	7,18E-04	4,06E-04	4,53E-03	4,06E-03	6,45E-03	7,71E-03	7,83E-03	9,25E-03
14	3,42E-04	2,96E-04	8,88E-04	2,71E-04	3,98E-03	4,26E-03	6,54E-03	8,13E-03	7,78E-03	9,63E-03
15	2,91E-04	4,27E-04	6,69E-04	3,64E-04	3,84E-03	3,98E-03	6,62E-03	7,61E-03	8,09E-03	9,52E-03

Tabela P1.6 Uticaj broja neurona u skrivenom sloju neuronske mreže na koeficijent determinacije (R^2) objedinjenih podataka mikrofiltracije kultivacione tečnosti *Streptomyces hygroscopicus* sa i bez prisustva statičkog mešača (SM i NSM) u uslovima ugušćivanja

	Model									
	trainlm		trainbr		trainrp		trainscg		trainoss	
	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig
1	0,94917	0,94746	0,94939	0,94939	0,91818	0,93246	0,94517	0,94219	0,94105	0,91942
2	0,96619	0,96744	0,96880	0,96880	0,94230	0,94899	0,95045	0,94184	0,94381	0,93197
3	0,97754	0,97770	0,97741	0,97741	0,95149	0,95504	0,95320	0,94658	0,94542	0,94012
4	0,98695	0,98686	0,98675	0,98675	0,95177	0,96338	0,95602	0,95071	0,94927	0,94211
5	0,99195	0,99149	0,99055	0,99055	0,96057	0,96910	0,95531	0,95070	0,95097	0,94337
6	0,99351	0,99444	0,99326	0,99326	0,96312	0,97075	0,95377	0,95343	0,94870	0,94336
7	0,99392	0,99569	0,99259	0,99259	0,97035	0,97006	0,95164	0,94971	0,94987	0,94266
8	0,99553	0,99375	0,99330	0,99330	0,96855	0,97428	0,95402	0,95047	0,94895	0,94284
9	0,99678	0,99607	0,99488	0,99488	0,96973	0,97093	0,95314	0,94528	0,95263	0,94367
10	0,99651	0,99619	0,99488	0,99488	0,97005	0,97494	0,95556	0,94727	0,94995	0,94330
11	0,99740	0,99593	0,99501	0,99501	0,96889	0,97590	0,95585	0,94717	0,94973	0,94293
12	0,99745	0,99637	0,99612	0,99612	0,96904	0,97630	0,95448	0,94838	0,95056	0,94182
13	0,99780	0,99639	0,99523	0,99523	0,97167	0,97450	0,95265	0,94836	0,94760	0,94129
14	0,99770	0,99803	0,99418	0,99418	0,97529	0,97346	0,95243	0,94379	0,94773	0,94062
15	0,99805	0,99702	0,99549	0,99549	0,97623	0,97543	0,95159	0,94864	0,94538	0,94025

Tabela P1.7 Eksperimentalno utvrđene i modelom neuronske mreže predviđene vrednosti fuksa permeata mikrofiltracije kultivacione tečnosti *Streptomyces hygroscopicus* sa i bez prisustva statičkog mešača (SM i NSM) u uslovima ugušćivanja

NSM režim			SM režim		
$t(s)$	$J_{exp,NSM}$	$J_{pred,NSM}$	$t(s)$	$J_{exp,SM}$	$J_{pred,SM}$
50	95,00000	94,50000	43	194,69984	194,26984
105	79,73422	78,68422	87	192,46191	191,59191
270	62,01550	59,31550	136	184,67852	183,31852
475	52,87638	52,40138	200	175,00000	173,00000
680	49,24761	48,56761	246	170,16449	167,70449
885	47,29996	46,41496	304	165,23868	162,19868
1105	45,45933	44,35433	362	161,89130	161,52930
1293	44,65598	43,07746	417	160,61569	160,19869
1540	43,49139	41,95139	483	156,00173	155,51873
1760	42,81184	41,05184	556	153,00000	152,44400
2000	41,86047	41,66047	606	151,96869	151,36269
2240	41,11296	40,88896	673	149,27952	148,60652
2510	40,02594	39,77494	743	146,48346	145,74046
2790	39,00975	38,73075	806	145,42097	144,61497
3080	38,05497	37,74697	880	142,70613	141,82613
3380	37,15426	36,81626	954	140,41246	139,45846
3680	36,40040	36,03240	1026	136,00000	137,69289
3980	35,76020	35,36220	1102	135,00000	135,64725
4280	35,20974	34,78174	1172	135,72506	134,55306
4580	34,73139	34,27339	1247	135,00000	133,02875
4880	34,31186	33,82386			
5180	33,94092	33,42292			
5480	33,61059	33,06259			
5780	33,31456	32,73656			
6080	33,04774	32,43974			
6380	32,80601	32,16801			

PRILOG 2.

Tabela P2.1. Uticaj broja neurona u skrivenom sloju neuronske mreže na srednju kvadratnu grešku (MSE) podataka mikrofiltracije kultivacione tečnosti *Bacillus velezensis* bez prisustva statičkog mešača (NSM) u uslovima recirkulacije napojne smeše

	Model									
	trainlm		trainbr		trainrp		trainseg		trainoss	
	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig
1	2,22E-02	2,22E-02	2,26E-02	2,26E-02	2,48E-02	2,34E-02	2,27E-02	2,27E-02	2,38E-02	2,43E-02
2	9,78E-03	8,14E-03	1,21E-02	1,71E-02	2,48E-02	2,31E-02	2,13E-02	2,17E-02	2,39E-02	2,49E-02
3	4,56E-03	3,07E-03	3,10E-03	3,39E-03	2,50E-02	2,21E-02	2,10E-02	2,22E-02	2,43E-02	2,48E-02
4	2,34E-03	2,66E-03	2,37E-03	2,44E-03	2,50E-02	2,31E-02	2,11E-02	2,28E-02	2,44E-02	2,54E-02
5	1,48E-03	1,24E-03	1,34E-03	1,32E-03	2,48E-02	2,23E-02	2,04E-02	2,25E-02	2,56E-02	2,54E-02
6	5,92E-04	5,73E-04	3,61E-04	5,69E-04	2,52E-02	2,28E-02	2,05E-02	2,35E-02	2,59E-02	2,58E-02
7	3,18E-04	3,33E-04	2,97E-04	2,91E-04	2,53E-02	2,30E-02	1,99E-02	2,33E-02	2,61E-02	2,62E-02
8	2,50E-04	1,49E-04	1,96E-04	2,09E-04	2,59E-02	2,28E-02	2,11E-02	2,45E-02	2,63E-02	2,66E-02
9	1,53E-04	1,43E-04	1,37E-04	1,78E-04	2,59E-02	2,08E-02	2,15E-02	2,52E-02	2,60E-02	2,59E-02
10	1,31E-04	1,51E-04	1,14E-04	1,40E-04	2,59E-02	2,20E-02	2,02E-02	2,50E-02	2,69E-02	2,66E-02
11	1,05E-04	1,16E-04	1,30E-04	1,36E-04	2,58E-02	2,03E-02	2,18E-02	2,51E-02	2,63E-02	2,63E-02
12	1,06E-04	1,17E-04	9,47E-05	1,06E-04	2,67E-02	2,12E-02	2,21E-02	2,51E-02	2,65E-02	2,64E-02
13	1,01E-04	9,97E-05	1,11E-04	1,05E-04	2,52E-02	2,05E-02	2,16E-02	2,51E-02	2,71E-02	2,68E-02
14	7,93E-05	1,09E-04	1,26E-04	9,46E-05	2,60E-02	2,14E-02	2,19E-02	2,53E-02	2,66E-02	2,64E-02
15	9,38E-05	1,04E-04	8,64E-05	1,10E-04	2,67E-02	2,10E-02	2,24E-02	2,55E-02	2,70E-02	2,65E-02

Tabela P2.2. Uticaj broja neurona u skrivenom sloju neuronske mreže na koeficijent determinacije (R^2) podataka mikrofiltracije kultivacione tečnosti *Bacillus velezensis* bez prisustva statičkog mešača (NSM) u uslovima recirkulacije napojne smeše

	Model									
	trainlm		trainbr		trainrp		trainseg		trainoss	
	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig
1	0,74749	0,74893	0,74353	0,74586	0,70381	0,73911	0,73749	0,74034	0,71623	0,71848
2	0,88724	0,89751	0,86497	0,79725	0,69476	0,74006	0,74583	0,73938	0,70517	0,70848
3	0,95286	0,97110	0,97061	0,96699	0,69398	0,75330	0,74439	0,72758	0,70015	0,70276
4	0,97660	0,97449	0,97710	0,97578	0,68544	0,73883	0,73896	0,72077	0,70081	0,69974
5	0,98574	0,98801	0,98676	0,98718	0,69129	0,74744	0,74941	0,72981	0,68634	0,69672
6	0,99380	0,99403	0,99622	0,99366	0,68842	0,74051	0,74487	0,71077	0,68297	0,69010
7	0,99689	0,99647	0,99726	0,99709	0,68470	0,73888	0,75225	0,71821	0,67657	0,68805
8	0,99758	0,99850	0,99806	0,99789	0,67718	0,73785	0,74265	0,69653	0,67775	0,67937
9	0,99859	0,99860	0,99867	0,99816	0,67532	0,76286	0,73165	0,69244	0,68423	0,69037
10	0,99876	0,99850	0,99893	0,99859	0,68034	0,74888	0,74153	0,69343	0,66971	0,67904
11	0,99886	0,99873	0,99876	0,99853	0,68190	0,76983	0,72882	0,69254	0,67690	0,68055
12	0,99898	0,99880	0,99909	0,99896	0,66400	0,75624	0,71978	0,68787	0,67331	0,68268
13	0,99902	0,99900	0,99894	0,99896	0,69394	0,76571	0,72670	0,69363	0,66698	0,67728
14	0,99922	0,99886	0,99875	0,99900	0,67975	0,75030	0,72543	0,68839	0,67475	0,67914
15	0,99908	0,99888	0,99919	0,99887	0,67060	0,75570	0,71650	0,68799	0,66841	0,68140

Tabela P2.3 Uticaj broja neurona u skrivenom sloju neuronske mreže na srednju kvadratnu grešku (MSE) podataka mikrofiltracije kultivacione tečnosti *Bacillus velezensis* u prisustvu statičkog mešača (SM) u uslovima recirkulacije napojne smeše

	Model									
	trainlm		trainbr		trainrp		trainscg		trainoss	
	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig
1	5,68E-03	5,68E-03	5,65E-03	5,65E-03	5,72E-03	5,58E-03	5,73E-03	5,82E-03	5,74E-03	5,76E-03
2	2,33E-03	2,14E-03	1,94E-03	2,52E-03	4,95E-03	4,51E-03	5,39E-03	5,18E-03	5,29E-03	5,53E-03
3	8,32E-04	7,97E-04	7,30E-04	6,82E-04	4,70E-03	1,56E-03	4,86E-03	5,06E-03	5,35E-03	5,36E-03
4	5,99E-04	5,65E-04	6,36E-04	6,13E-04	4,44E-03	1,10E-03	4,21E-03	4,78E-03	5,09E-03	5,30E-03
5	3,73E-04	3,31E-04	3,12E-04	4,38E-04	3,56E-03	1,02E-03	4,68E-03	4,37E-03	5,20E-03	5,46E-03
6	2,68E-04	2,94E-04	2,33E-04	2,39E-04	3,44E-03	7,97E-04	4,61E-03	4,78E-03	5,29E-03	5,40E-03
7	2,55E-04	2,81E-04	2,46E-04	2,58E-04	3,48E-03	1,00E-03	4,74E-03	4,30E-03	5,30E-03	5,56E-03
8	2,73E-04	2,54E-04	2,75E-04	3,58E-04	3,32E-03	9,47E-04	4,56E-03	4,63E-03	5,19E-03	5,32E-03
9	2,51E-04	2,44E-04	2,83E-04	4,50E-04	2,96E-03	6,19E-04	4,04E-03	4,86E-03	5,29E-03	5,50E-03
10	2,76E-04	2,40E-04	2,69E-04	4,57E-04	2,47E-03	9,93E-04	4,60E-03	5,11E-03	5,06E-03	5,74E-03
11	2,30E-04	2,44E-04	2,82E-04	5,74E-04	2,54E-03	8,75E-04	4,23E-03	5,31E-03	5,08E-03	5,53E-03
12	2,27E-04	2,40E-04	2,84E-04	9,50E-04	2,42E-03	6,73E-04	4,49E-03	4,83E-03	5,19E-03	5,73E-03
13	2,25E-04	2,33E-04	2,67E-04	5,48E-04	2,56E-03	6,09E-04	4,51E-03	5,32E-03	5,55E-03	5,79E-03
14	2,38E-04	2,40E-04	3,47E-04	7,19E-04	2,09E-03	6,36E-04	3,52E-03	5,07E-03	5,47E-03	5,77E-03
15	2,30E-04	2,40E-04	3,92E-04	2,80E-04	2,37E-03	8,64E-04	4,18E-03	5,27E-03	5,28E-03	5,74E-03

Tabela P2.4 Uticaj broja neurona u skrivenom sloju neuronske mreže na koeficijent determinacije (R^2) podataka mikrofiltracije kultivacione tečnosti *Bacillus velezensis* u prisustvu statičkog mešača (SM) u uslovima recirkulacije napojne smeše

	Model									
	trainlm		trainbr		trainrp		trainscg		trainoss	
	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig
1	0,89457	0,89463	0,89503	0,89498	0,89331	0,89236	0,89163	0,88727	0,89220	0,89284
2	0,95585	0,96064	0,96459	0,95133	0,90686	0,91550	0,89297	0,89878	0,89823	0,89686
3	0,98598	0,98646	0,98763	0,98861	0,91070	0,96938	0,90383	0,89905	0,89513	0,89828
4	0,98967	0,99115	0,98889	0,98925	0,91564	0,97913	0,91580	0,90484	0,89905	0,90056
5	0,99290	0,99408	0,99387	0,99180	0,93244	0,98112	0,90571	0,91540	0,89886	0,89790
6	0,99453	0,99419	0,99516	0,99493	0,93415	0,98595	0,90703	0,90614	0,89601	0,89988
7	0,99502	0,99458	0,99515	0,99495	0,93319	0,98145	0,90531	0,91447	0,89410	0,89481
8	0,99481	0,99510	0,99509	0,99331	0,93685	0,98252	0,90752	0,90652	0,89796	0,89904
9	0,99545	0,99538	0,99493	0,99137	0,94424	0,98920	0,91893	0,90280	0,89575	0,89614
10	0,99485	0,99548	0,99517	0,99150	0,95410	0,98166	0,90774	0,89733	0,90178	0,89155
11	0,99563	0,99543	0,99502	0,98948	0,95148	0,98376	0,91378	0,89572	0,90150	0,89534
12	0,99569	0,99560	0,99501	0,98165	0,95498	0,98799	0,90873	0,90310	0,89989	0,89070
13	0,99560	0,99568	0,99521	0,98974	0,95194	0,98904	0,90943	0,89439	0,89300	0,88982
14	0,99534	0,99550	0,99314	0,98559	0,96107	0,98873	0,92981	0,89903	0,89268	0,89112
15	0,99557	0,99545	0,99275	0,99513	0,95579	0,98453	0,91329	0,89763	0,89858	0,89125

Tabela P2.5. Uticaj broja neurona u skrivenom sloju neuronske mreže na srednju kvadratnu grešku (MSE) objedinjenih podataka mikrofiltracije kultivacione tečnosti *Bacillus velezensis* sa i bez prisustva statičkog mešača (SM i NSM) u uslovima recirkulacije napojne smeše

	Model									
	trainlm		trainbr		trainrp		trainscg		trainoss	
	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig
1	5,68E-03	5,68E-03	5,65E-03	5,65E-03	5,72E-03	5,58E-03	5,73E-03	5,82E-03	5,74E-03	5,76E-03
2	2,33E-03	2,14E-03	1,94E-03	2,52E-03	4,95E-03	4,51E-03	5,39E-03	5,18E-03	5,29E-03	5,53E-03
3	8,32E-04	7,97E-04	7,30E-04	6,82E-04	4,70E-03	1,56E-03	4,86E-03	5,06E-03	5,35E-03	5,36E-03
4	5,99E-04	5,65E-04	6,36E-04	6,13E-04	4,44E-03	1,10E-03	4,21E-03	4,78E-03	5,09E-03	5,30E-03
5	3,73E-04	3,31E-04	3,12E-04	4,38E-04	3,56E-03	1,02E-03	4,68E-03	4,37E-03	5,20E-03	5,46E-03
6	2,68E-04	2,94E-04	2,33E-04	2,39E-04	3,44E-03	7,97E-04	4,61E-03	4,78E-03	5,29E-03	5,40E-03
7	2,55E-04	2,81E-04	2,46E-04	2,58E-04	3,48E-03	1,00E-03	4,74E-03	4,30E-03	5,30E-03	5,56E-03
8	2,73E-04	2,54E-04	2,75E-04	3,58E-04	3,32E-03	9,47E-04	4,56E-03	4,63E-03	5,19E-03	5,32E-03
9	2,51E-04	2,44E-04	2,83E-04	4,50E-04	2,96E-03	6,19E-04	4,04E-03	4,86E-03	5,29E-03	5,50E-03
10	2,76E-04	2,40E-04	2,69E-04	4,57E-04	2,47E-03	9,93E-04	4,60E-03	5,11E-03	5,06E-03	5,74E-03
11	2,30E-04	2,44E-04	2,82E-04	5,74E-04	2,54E-03	8,75E-04	4,23E-03	5,31E-03	5,08E-03	5,53E-03
12	2,27E-04	2,40E-04	2,84E-04	9,50E-04	2,42E-03	6,73E-04	4,49E-03	4,83E-03	5,19E-03	5,73E-03
13	2,25E-04	2,33E-04	2,67E-04	5,48E-04	2,56E-03	6,09E-04	4,51E-03	5,32E-03	5,55E-03	5,79E-03
14	2,38E-04	2,40E-04	3,47E-04	7,19E-04	2,09E-03	6,36E-04	3,52E-03	5,07E-03	5,47E-03	5,77E-03
15	2,30E-04	2,40E-04	3,92E-04	2,80E-04	2,37E-03	8,64E-04	4,18E-03	5,27E-03	5,28E-03	5,74E-03

Tabela P2.6. Uticaj broja neurona u skrivenom sloju neuronske mreže na koeficijent determinacije (R^2) objedinjenih podataka mikrofiltracije kultivacione tečnosti *Bacillus velezensis* sa i bez prisustva statičkog mešača (SM i NSM) u uslovima recirkulacije napojne smeše

	Model									
	trainlm		trainbr		trainrp		trainscg		trainoss	
	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig
1	0,90747	0,91033	0,90968	0,90963	0,90267	0,90150	0,90775	0,90775	0,90461	0,89924
2	0,92457	0,92625	0,92537	0,92362	0,91558	0,90974	0,91926	0,91926	0,91486	0,91065
3	0,94998	0,96206	0,97225	0,96720	0,92709	0,92553	0,92828	0,92828	0,92166	0,91491
4	0,97392	0,97519	0,98327	0,98457	0,93145	0,92904	0,92778	0,92778	0,92344	0,91501
5	0,98986	0,99013	0,99133	0,99085	0,93382	0,93192	0,93303	0,93303	0,92350	0,91659
6	0,99415	0,99419	0,99518	0,99382	0,93567	0,93786	0,93416	0,93416	0,92505	0,91636
7	0,99521	0,99443	0,99633	0,99642	0,93560	0,93960	0,93424	0,93424	0,92430	0,91505
8	0,99706	0,99740	0,99736	0,99757	0,93498	0,94176	0,93532	0,93532	0,92550	0,91653
9	0,99806	0,99750	0,99808	0,99798	0,93556	0,94147	0,93771	0,93771	0,92287	0,91826
10	0,99843	0,99848	0,99749	0,99852	0,93617	0,94459	0,93575	0,93575	0,92842	0,91534
11	0,99880	0,99865	0,99875	0,99869	0,93648	0,94468	0,93490	0,93490	0,92460	0,91365
12	0,99893	0,99886	0,99897	0,99890	0,93757	0,94710	0,93602	0,93602	0,92636	0,91631
13	0,99917	0,99905	0,99906	0,99907	0,93765	0,94952	0,93785	0,93785	0,91860	0,91456
14	0,99919	0,99918	0,99918	0,99920	0,93772	0,94966	0,93713	0,93713	0,92206	0,91519
15	0,99933	0,99927	0,99933	0,99923	0,93708	0,94798	0,93153	0,93153	0,92260	0,91464

Tabela P2.7. Eksperimentalno utvrđene i modelom neuronske mreže predviđene vrednosti fuksa permeata mikrofiltracije kultivacione tečnosti *Bacillus velezensis* sa i bez prisustva statičkog mešača (SM i NSM) u uslovima recirkulacije napojne smeše

NSM režim			SM režim		
t(s)	J _{exp,NSM}	J _{pred,NSM}	t(s)	J _{exp,SM}	J _{pred,SM}
45	171,55896	171,55896	50	162,27005	162,27005
117	108,43596	108,43596	120	111,47651	111,47651
218	77,51127	77,51127	215	84,43177	84,43177
349	59,60535	59,60535	313	76,10321	76,10321
513	47,45559	47,45559	420	72,74279	72,74279
710	39,57444	39,57444	530	70,46670	70,46670
919	37,13935	37,13935	642	69,89154	69,89154
1158	32,70739	32,70739	756	68,46080	68,46080
1408	31,09421	31,09421	872	66,96638	66,96638
1684	28,25106	28,25106	990	66,19835	66,19835
1976	26,69021	26,69021	1108	65,94624	65,94624
2282	25,43979	25,43979	1227	65,42027	65,42027
2599	24,63394	24,63394	1345	66,23774	66,23774
2916	24,58808	24,58808	1465	64,93506	64,93506
3249	23,34464	23,34464	1584	65,05433	65,05433
3601	22,19244	22,19244	1704	65,23952	65,23952
3958	21,78724	21,78724	1823	65,15224	65,15224
4327	21,13198	21,13198	1943	65,05976	65,05976
4697	21,05888	21,05888	2063	64,88640	64,88640
5077	20,51715	20,51715	2183	65,06520	65,06520

PRILOG 3.

Tabela P3.1. Uticaj broja neurona u skrivenom sloju neuronske mreže na srednju kvadratnu grešku (MSE) podataka mikrofiltracije kultivacione tečnosti *Bacillus velezensis* u uslovima dvofaznog toka

	Model									
	trainlm		trainbr		trainrp		trainseg		trainoss	
	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig
1	1,38E-02	1,38E-02	1,45E-02	1,46E-02	1,67E-02	1,92E-02	1,42E-02	1,49E-02	1,56E-02	1,80E-02
2	6,50E-03	7,38E-03	3,86E-03	2,83E-03	1,54E-02	1,88E-02	1,22E-02	1,37E-02	1,52E-02	1,67E-02
3	3,27E-03	1,69E-03	2,01E-03	1,70E-03	1,51E-02	1,80E-02	1,20E-02	1,45E-02	1,48E-02	1,66E-02
4	2,22E-03	1,37E-03	1,11E-03	1,26E-03	1,54E-02	1,79E-02	1,22E-02	1,46E-02	1,52E-02	1,64E-02
5	2,83E-03	1,20E-03	1,39E-03	1,31E-03	1,54E-02	1,75E-02	1,22E-02	1,47E-02	1,50E-02	1,61E-02
6	2,34E-03	1,26E-03	1,37E-03	1,31E-03	1,52E-02	1,73E-02	1,22E-02	1,44E-02	1,52E-02	1,59E-02
7	1,85E-03	1,36E-03	1,35E-03	1,41E-03	1,55E-02	1,72E-02	1,27E-02	1,48E-02	1,52E-02	1,58E-02
8	1,81E-03	1,35E-03	1,29E-03	1,40E-03	1,53E-02	1,71E-02	1,27E-02	1,49E-02	1,54E-02	1,62E-02
9	1,95E-03	1,48E-03	1,33E-03	1,47E-03	1,55E-02	1,71E-02	1,35E-02	1,50E-02	1,53E-02	1,62E-02
10	2,08E-03	1,37E-03	1,44E-03	1,42E-03	1,56E-02	1,66E-02	1,33E-02	1,49E-02	1,54E-02	1,60E-02
11	1,76E-03	1,86E-03	1,53E-03	1,66E-03	1,56E-02	1,70E-02	1,21E-02	1,53E-02	1,55E-02	1,60E-02
12	1,78E-03	1,53E-03	1,52E-03	1,59E-03	1,55E-02	1,69E-02	1,27E-02	1,52E-02	1,52E-02	1,61E-02
13	1,90E-03	1,55E-03	1,58E-03	1,65E-03	1,57E-02	1,66E-02	1,30E-02	1,54E-02	1,56E-02	1,60E-02
14	1,73E-03	1,61E-03	1,55E-03	1,59E-03	1,57E-02	1,69E-02	1,33E-02	1,52E-02	1,55E-02	1,62E-02
15	1,47E-03	1,53E-03	1,60E-03	1,57E-03	1,56E-02	1,68E-02	1,30E-02	1,55E-02	1,54E-02	1,59E-02

Tabela P3.2. Uticaj broja neurona u skrivenom sloju neuronske mreže na koeficijent determinacije (R^2) podataka mikrofiltracije kultivacione tečnosti *Bacillus velezensis* u uslovima dvofaznog toka

	Model									
	trainlm		trainbr		trainrp		trainseg		trainoss	
	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig
1	0,76876	0,76768	0,76135	0,76017	0,70183	0,64548	0,76296	0,74408	0,73170	0,67478
2	0,89345	0,88184	0,94281	0,96033	0,74122	0,64985	0,77296	0,75266	0,73512	0,71034
3	0,94678	0,97482	0,97253	0,97632	0,74535	0,67204	0,76186	0,74400	0,74099	0,71194
4	0,96475	0,97802	0,98392	0,98181	0,74030	0,66692	0,77282	0,74681	0,74279	0,72296
5	0,94968	0,98248	0,97950	0,98055	0,74155	0,68323	0,76951	0,74340	0,73899	0,72772
6	0,96572	0,98209	0,98010	0,98070	0,74318	0,69297	0,77050	0,74914	0,73992	0,72967
7	0,97152	0,98141	0,98009	0,97909	0,73426	0,69596	0,77012	0,74291	0,73659	0,73308
8	0,97292	0,98261	0,98226	0,98034	0,74467	0,69517	0,76637	0,74516	0,73897	0,72483
9	0,97296	0,97942	0,98163	0,97929	0,73905	0,69757	0,76253	0,74258	0,74035	0,72366
10	0,96595	0,98107	0,97964	0,97984	0,74215	0,71006	0,76562	0,74547	0,74121	0,72972
11	0,97411	0,97072	0,97885	0,97644	0,73957	0,69992	0,77997	0,73695	0,73841	0,72798
12	0,97379	0,97903	0,97917	0,97758	0,74178	0,70541	0,77281	0,73429	0,73879	0,73263
13	0,96897	0,97917	0,97843	0,97717	0,74352	0,70879	0,76810	0,74022	0,73376	0,73120
14	0,97568	0,97773	0,97849	0,97766	0,73842	0,70698	0,76658	0,73676	0,74119	0,72922
15	0,97882	0,97890	0,97829	0,97763	0,74242	0,70858	0,76267	0,73894	0,74198	0,73321

Tabela P3.3. Eksperimentalno utvrđene i modelom neuronske mreže predviđene vrednosti fuksa permeata mikrofiltracije kultivacione tečnosti *Bacillus velezensis* u uslovima dvofaznog toka

t(s)	Dvofazni tok	
	$J_{\text{exp, vazduh}}$	$J_{\text{pred, vazduh}}$
45	171,55896	171,55896
117	108,43596	108,43596
218	77,51127	77,51127
349	59,60535	59,60535
513	47,45559	47,45559
710	39,57444	39,57444
919	37,13935	37,13935
1158	32,70739	32,70739
1408	31,09421	31,09421
1684	28,25106	28,25106
1976	26,69021	26,69021
2282	25,43979	25,43979
2599	24,63394	24,63394
2916	24,58808	24,58808
3249	23,34464	23,34464
3601	22,19244	22,19244
3958	21,78724	21,78724
4327	21,13198	21,13198
4697	21,05888	21,05888
5077	20,51715	20,51715

PRILOG 4.

Tabela P4.1. Uticaj broja neurona u skrivenom sloju neuronske mreže na srednju kvadratnu grešku (MSE) podataka mikrofiltracije kultivacione tečnosti *Bacillus velezensis* u uslovima kombinovanog postupka (uduvavanja vazduha i postavljanja statičkog mešača)

	Model									
	trainlm		trainbr		trainrp		trainscg		trainoss	
	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig
1	1,69E-02	1,69E-02	1,71E-02	1,71E-02	1,92E-02	1,97E-02	1,75E-02	1,87E-02	1,85E-02	1,97E-02
2	6,49E-03	5,70E-03	5,13E-03	5,17E-03	1,89E-02	1,90E-02	1,58E-02	1,82E-02	1,84E-02	1,96E-02
3	3,50E-03	2,43E-03	2,27E-03	2,98E-03	1,86E-02	1,86E-02	1,56E-02	1,75E-02	1,87E-02	1,95E-02
4	1,93E-03	1,54E-03	1,86E-03	1,85E-03	1,85E-02	1,82E-02	1,55E-02	1,79E-02	1,88E-02	1,97E-02
5	1,81E-03	1,10E-03	1,07E-03	1,21E-03	1,75E-02	1,79E-02	1,52E-02	1,82E-02	1,87E-02	1,95E-02
6	1,45E-03	8,87E-04	1,07E-03	9,53E-04	1,78E-02	1,74E-02	1,51E-02	1,87E-02	1,90E-02	1,97E-02
7	9,00E-04	7,93E-04	7,57E-04	7,76E-04	1,80E-02	1,74E-02	1,49E-02	1,87E-02	1,89E-02	1,95E-02
8	8,95E-04	7,14E-04	7,81E-04	6,77E-04	1,84E-02	1,67E-02	1,56E-02	1,86E-02	1,90E-02	1,96E-02
9	6,51E-04	6,74E-04	6,83E-04	5,98E-04	1,84E-02	1,60E-02	1,63E-02	1,82E-02	1,89E-02	1,99E-02
10	5,32E-04	5,30E-04	8,17E-04	6,30E-04	1,88E-02	1,69E-02	1,57E-02	1,87E-02	1,91E-02	1,97E-02
11	6,04E-04	6,48E-04	6,49E-04	5,71E-04	1,85E-02	1,72E-02	1,57E-02	1,83E-02	1,94E-02	1,97E-02
12	5,72E-04	5,32E-04	6,33E-04	5,63E-04	1,79E-02	1,83E-02	1,58E-02	1,85E-02	1,92E-02	1,96E-02
13	5,25E-04	4,73E-04	7,45E-04	5,42E-04	1,81E-02	1,61E-02	1,56E-02	1,87E-02	1,94E-02	1,95E-02
14	5,38E-04	4,40E-04	5,78E-04	4,53E-04	1,87E-02	1,70E-02	1,58E-02	1,89E-02	1,94E-02	1,95E-02
15	4,71E-04	5,94E-04	5,55E-04	5,79E-04	1,90E-02	1,62E-02	1,63E-02	1,87E-02	1,95E-02	1,94E-02

Tabela P4.2. Uticaj broja neurona u skrivenom sloju neuronske mreže na koeficijent determinacije (R^2) podataka mikrofiltracije kultivacione tečnosti *Bacillus velezensis* u uslovima kombinovanog postupka (uduvavanja vazduha i postavljanja statičkog mešača)

	Model									
	trainlm		trainbr		trainrp		trainscg		trainoss	
	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig
1	0,75797	0,75061	0,75199	0,76058	0,72990	0,71418	0,73154	0,71624	0,72902	0,70701
2	0,89045	0,89779	0,90404	0,90506	0,73571	0,72492	0,76050	0,72007	0,72900	0,70644
3	0,94052	0,95719	0,96528	0,93947	0,74079	0,73106	0,76767	0,73620	0,72661	0,71363
4	0,96775	0,97542	0,96558	0,96391	0,74232	0,74121	0,76520	0,72852	0,72203	0,70663
5	0,97252	0,98460	0,98425	0,98103	0,75655	0,74123	0,77042	0,72393	0,72619	0,71415
6	0,97769	0,98669	0,98381	0,98533	0,75215	0,75084	0,77292	0,71164	0,72622	0,70934
7	0,98713	0,98935	0,99036	0,98888	0,74861	0,75259	0,77421	0,72425	0,72547	0,71490
8	0,98504	0,99018	0,98886	0,99066	0,74336	0,76238	0,76297	0,71500	0,72604	0,70973
9	0,99034	0,99122	0,98956	0,99181	0,74413	0,77361	0,75852	0,72719	0,72656	0,70748
10	0,99219	0,99285	0,98842	0,99165	0,73640	0,75769	0,76553	0,71782	0,72107	0,71085
11	0,99167	0,99085	0,99155	0,99263	0,74163	0,75692	0,76436	0,72443	0,72107	0,71246
12	0,99189	0,99285	0,99169	0,99257	0,75034	0,74014	0,76135	0,72290	0,72577	0,71592
13	0,99302	0,99426	0,98991	0,99326	0,74626	0,77637	0,76816	0,71818	0,72039	0,71934
14	0,99299	0,99480	0,99275	0,99449	0,73977	0,76108	0,76831	0,71896	0,72176	0,71341
15	0,99404	0,99231	0,99175	0,99221	0,73235	0,77193	0,75497	0,72042	0,72028	0,71747

Tabela P4.3 Eksperimentalno utvrđene i modelom neuronske mreže predviđene vrednosti fuksa permeata mikrofiltracije kultivacione tečnosti Bacillus velezensis u uslovima kombinovanog postupka (udivavanja vazduha i postavljanja statičkog mešača)

SM i Dvofazni tok		
t(s)	J _{exp,kombinovano}	J _{pred,kombinovano}
43	180,50053	180,14794
116	106,53825	106,19298
198	95,65686	95,31974
282	92,34662	92,01793
369	89,47305	89,15307
457	88,67882	88,36763
546	87,38598	87,08371
636	86,96660	86,67329
726	86,71498	86,43065
817	85,54405	85,26884
908	85,14213	84,87607
1000	84,73475	84,47788
1092	85,04920	84,80149
1184	84,80853	84,57001

PRILOG 5.

Tabela P5.1. Uticaj broja neurona u skrivenom sloju neuronske mreže na srednju kvadratnu grešku (MSE) objedinjenih podataka mikrofiltracije kultivacione tečnosti *Bacillus velezensis*

	Model									
	trainlm		trainbr		trainrp		trainscg		trainoss	
	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig
1	4,64E-03	4,64E-03	4,64E-03	4,64E-03	4,89E-03	4,85E-03	4,66E-03	4,70E-03	4,76E-03	5,59E-03
2	3,99E-03	3,82E-03	3,89E-03	4,03E-03	4,81E-03	4,49E-03	4,40E-03	4,69E-03	4,62E-03	5,44E-03
3	2,11E-03	1,77E-03	1,76E-03	1,90E-03	4,63E-03	4,24E-03	4,22E-03	4,59E-03	4,61E-03	5,23E-03
4	1,39E-03	1,33E-03	1,35E-03	1,37E-03	4,48E-03	3,92E-03	4,10E-03	4,54E-03	4,56E-03	5,48E-03
5	1,04E-03	1,01E-03	9,22E-04	1,08E-03	4,43E-03	3,52E-03	3,84E-03	4,63E-03	4,56E-03	5,21E-03
6	7,34E-04	7,06E-04	7,20E-04	7,08E-04	4,53E-03	3,55E-03	3,87E-03	4,64E-03	4,39E-03	5,49E-03
7	5,70E-04	5,52E-04	5,34E-04	5,70E-04	4,37E-03	3,33E-03	3,93E-03	4,91E-03	4,61E-03	5,13E-03
8	4,82E-04	4,61E-04	4,63E-04	4,64E-04	4,33E-03	3,24E-03	3,91E-03	4,59E-03	4,61E-03	5,51E-03
9	3,98E-04	3,91E-04	3,97E-04	4,04E-04	4,35E-03	3,31E-03	3,66E-03	4,95E-03	4,67E-03	5,17E-03
10	3,54E-04	3,63E-04	3,56E-04	3,62E-04	4,35E-03	3,31E-03	3,63E-03	4,93E-03	4,65E-03	5,44E-03
11	3,34E-04	3,21E-04	3,26E-04	3,13E-04	4,45E-03	3,45E-03	3,77E-03	4,92E-03	4,69E-03	5,49E-03
12	2,97E-04	3,09E-04	3,12E-04	2,98E-04	4,40E-03	3,33E-03	3,91E-03	5,27E-03	4,87E-03	5,41E-03
13	2,76E-04	2,89E-04	2,93E-04	2,90E-04	4,51E-03	3,17E-03	3,87E-03	5,29E-03	4,75E-03	5,66E-03
14	2,69E-04	2,82E-04	2,76E-04	2,74E-04	4,52E-03	3,12E-03	3,92E-03	5,29E-03	4,90E-03	5,61E-03
15	2,64E-04	2,60E-04	2,74E-04	2,75E-04	4,33E-03	3,14E-03	3,86E-03	5,27E-03	4,54E-03	5,91E-03

Tabela P5.2. Uticaj broja neurona u skrivenom sloju neuronske mreže na koeficijent determinacije (R^2) objedinjenih podataka mikrofiltracije kultivacione tečnosti *Bacillus velezensis*

	Model									
	trainlm		trainbr		trainrp		trainscg		trainoss	
	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig	tansig	logsig
1	0,91663	0,91650	0,91658	0,91656	0,91085	0,91243	0,91550	0,91428	0,91310	0,89584
2	0,92790	0,93079	0,92885	0,92709	0,91175	0,91908	0,91943	0,91292	0,91507	0,89848
3	0,96260	0,96868	0,96904	0,96662	0,91455	0,92287	0,92149	0,91498	0,91532	0,90271
4	0,97557	0,97626	0,97635	0,97593	0,91757	0,92851	0,92293	0,91533	0,91602	0,89778
5	0,98163	0,98220	0,98373	0,98093	0,91819	0,93583	0,92767	0,91360	0,91505	0,90355
6	0,98697	0,98761	0,98732	0,98755	0,91620	0,93533	0,92695	0,91341	0,91857	0,89758
7	0,98999	0,99019	0,99060	0,98997	0,91932	0,93921	0,92562	0,90713	0,91412	0,90490
8	0,99144	0,99188	0,99185	0,99185	0,92019	0,94086	0,92633	0,91417	0,91453	0,89750
9	0,99291	0,99305	0,99294	0,99284	0,91925	0,93946	0,93034	0,90536	0,91351	0,90434
10	0,99364	0,99348	0,99368	0,99359	0,91929	0,93918	0,93144	0,90772	0,91368	0,89845
11	0,99404	0,99427	0,99420	0,99442	0,91756	0,93665	0,92834	0,90673	0,91274	0,89758
12	0,99465	0,99444	0,99443	0,99465	0,91831	0,93864	0,92541	0,90072	0,90940	0,89926
13	0,99498	0,99483	0,99475	0,99483	0,91614	0,94184	0,92617	0,90100	0,91213	0,89439
14	0,99513	0,99499	0,99503	0,99515	0,91629	0,94280	0,92577	0,89976	0,90848	0,89500
15	0,99532	0,99539	0,99513	0,99513	0,91986	0,94227	0,92652	0,89905	0,91574	0,88888

Tabela P5.3. Eksperimentalno utvrđene i modelom neuronske mreže predviđene vrednosti fiksa permeata mikrofiltracije kultivacione tečnosti *Bacillus velezensis*

Objedinjeni podaci		
t(s)	J _{exp,ukupno}	J _{pred,ukupno}
50	94,80000	94,35000
105	79,53422	78,53422
270	61,81550	59,16550
475	52,67638	52,25138
680	49,04761	48,41761
885	47,09996	46,26496
1105	45,25933	44,20433
1293	44,45598	42,92746
1540	43,29139	41,80139
1760	42,61184	40,90184
2000	41,66047	41,51047
2240	40,91296	40,73896
2510	39,82594	39,62494
2790	38,80975	38,58075
3080	37,85497	37,59697
3380	36,95426	36,66626
3680	36,20040	35,88240
3980	35,56020	35,21220
4280	35,00974	34,63174
4580	34,53139	34,12339

PRILOG 6.

Tabela P6.1. Uticaj broja neurona u skrivenom sloju neuronske mreže na srednju kvadratnu grešku (MSE) indeksa povećanja fluksa mikrofiltracije kultivacione tečnosti *Bacillus velezensis* u stacionarnim uslovima

	Model			
	trainlm		trainbr	
	tansig	logsig	tansig	logsig
1	6,34E-03	7,34E-03	6,28E-03	6,33E-03
2	7,20E-03	6,46E-03	4,37E-03	4,75E-03
3	5,67E-03	5,31E-03	3,61E-03	4,16E-03
4	3,16E-03	3,00E-03	2,46E-03	3,46E-03
5	1,61E-03	1,39E-03	2,59E-03	3,28E-03
6	1,20E-03	8,75E-04	2,67E-03	3,47E-03
7	5,04E-04	1,84E-04	2,85E-03	3,90E-03
8	1,24E-04	1,46E-05	3,02E-02	3,91E-03
9	4,24E-04	8,68E-05	2,92E-02	1,13E-02
10	1,44E-04	5,94E-06	2,92E-02	3,02E-02
11	1,73E-04	6,19E-05	3,16E-02	3,35E-02
12	1,49E-04	8,65E-06	3,05E-02	3,45E-02
13	1,88E-05	5,84E-06	2,98E-02	3,50E-02
14	3,00E-05	1,03E-04	2,91E-02	3,53E-02
15	1,52E-05	6,63E-05	3,01E-02	3,54E-02

Tabela P6.2. Uticaj broja neurona u skrivenom sloju neuronske mreže na koeficijent determinacije (R^2) indeksa povećanja fluksa mikrofiltracije kultivacione tečnosti *Bacillus velezensis* u stacionarnim uslovima

	Model			
	trainlm		trainbr	
	tansig	logsig	tansig	logsig
1	0,92078	0,88176	0,92071	0,92129
2	0,92152	0,93286	0,94647	0,94503
3	0,93184	0,93534	0,95987	0,94274
4	0,96009	0,96117	0,95626	0,94542
5	0,97694	0,97950	0,95580	0,94369
6	0,97962	0,98725	0,95894	0,94835
7	0,99305	0,99354	0,95846	0,94291
8	0,99694	0,99827	0,26666	0,93433
9	0,99295	0,99831	0,36798	0,72541
10	0,99651	0,99992	0,10630	0,23402
11	0,99745	0,99887	0,15138	0,24136
12	0,99740	0,99985	0,30902	0,25637
13	0,99914	0,99992	0,07726	0,29714
14	0,99881	0,99666	0,19141	0,24737
15	0,99893	0,99906	-0,03724	0,31097

Tabela P6.3. Uticaj broja neurona u skrivenom sloju neuronske mreže na srednju kvadratnu grešku (MSE) specifične potrošnje energije mikrofiltracije kultivacione tečnosti *Bacillus velezensis* u stacionarnim uslovima

	Model			
	trainlm		trainbr	
	tansig	logsig	tansig	logsig
1	2,56E-02	2,14E-02	2,65E-02	2,65E-02
2	2,11E-02	1,96E-02	2,65E-02	2,65E-02
3	1,53E-02	1,03E-02	2,65E-02	2,65E-02
4	6,52E-03	8,02E-03	2,65E-02	2,65E-02
5	3,51E-03	3,81E-03	2,65E-02	2,65E-02
6	2,52E-03	2,66E-03	2,65E-02	2,65E-02
7	2,50E-03	2,49E-03	2,65E-02	2,65E-02
8	2,50E-03	2,51E-03	2,65E-02	2,65E-02
9	2,50E-03	2,50E-03	2,65E-02	2,65E-02
10	2,50E-03	2,50E-03	2,65E-02	2,65E-02
11	2,50E-03	2,60E-03	2,65E-02	2,65E-02
12	2,50E-03	2,50E-03	2,65E-02	2,65E-02
13	2,50E-03	2,50E-03	2,65E-02	2,65E-02
14	2,50E-03	2,50E-03	2,65E-02	2,65E-02
15	2,50E-03	2,50E-03	2,65E-02	2,65E-02

Tabela P6.4. Uticaj broja neurona u skrivenom sloju neuronske mreže na koeficijent determinacije (R^2) specifične potrošnje energije mikrofiltracije kultivacione tečnosti *Bacillus velezensis* u stacionarnim uslovima

	Model			
	trainlm		trainbr	
	tansig	logsig	tansig	logsig
1	0,76894	0,80838	NaN	0,54911
2	0,77596	0,80138	-0,00094	0,59049
3	0,83526	0,90541	-0,09711	0,60137
4	0,89798	0,90526	0,06501	0,60606
5	0,94922	0,95644	-0,07036	0,26366
6	0,96407	0,96080	NaN	-0,19318
7	0,96942	0,96793	NaN	0,14303
8	0,96995	0,97031	NaN	0,68847
9	0,96838	0,96785	NaN	0,64316
10	0,96907	0,96636	NaN	0,66162
11	0,96962	0,96890	NaN	0,68360
12	0,96940	0,96967	NaN	0,65091
13	0,97017	0,96778	NaN	0,69427
14	0,96880	0,97045	NaN	0,63664
15	0,97103	0,96655	NaN	0,69636

План третмана података

Назив пројекта/истраживања
Моделовање микрофилтрације култивационих течности применом концепта вештачких неуронских мрежа
Назив институције/институција у оквиру којих се спроводи истраживање
а) Технолошки факултет Нови Сад, Универзитет у Новом Саду, (Србија) б) в)
Назив програма у оквиру ког се реализује истраживање
Пројекат који се реализује у оквиру програма Министарства просвете, науке и технолошког развоја: Унапређење производње биоетанола из производа прераде шећерне репе (ТР 31002)
1. Опис података
<i>1.1 Врста студије</i> <i>Укратко описати тип студије у оквиру које се подаци прикупљају</i> Докторска дисертација <hr/> <hr/> <hr/>
<i>1.2 Врсте података</i> а) <input type="checkbox"/> квантитативни б) <input checked="" type="checkbox"/> квалитативни
<i>1.3. Начин прикупљања података</i> а) анкете, упитници, тестови б) клиничке процене, медицински записи, електронски здравствени записи в) генотипови: навести врсту _____

- г) административни подаци: навести врсту _____
- д) узорци ткива: навести врсту _____
- ђ) снимци, фотографије: навести врсту _____
- е) текст, навести врсту __ литература _____
- ж) мапа, навести врсту _____
- з) остало: описати _____ вебсадржаји _____

1.3 Формат података, употребљене скале, количина података

1.3.1 Употребљени софтвер и формат датотеке:

- а) Excel фајл, датотека _____
- б) SPSS фајл, датотека _____
- в) PDF фајл, датотека _____
- г) Текст фајл, датотека _____
- д) JPG фајл, датотека _____
- е) Остало, датотека __ MATLAB R2012b _____

1.3.2. Број записа (код квантитативних података)

- а) број варијабли _____
- б) број мерења (испитаника, процена, снимака и сл.) _____

1.3.3. Поновљена мерења

а) да

б) не

Уколико је одговор да, одговорити на следећа питања:

- а) временски размак измедју поновљених мера је __нема правила _____
- б) варијабле које се више пута мере односе се на __експерименти су понављани 30 пута, нормализоване вредности флукса. специфичне потрошње енергије _____
- в) нове верзије фајлова који садрже поновљена мерења су именоване као _____

Напомене: _____

Да ли формати и софтвер омогућавају дељење и дугорочну валидност података?

а) Да

б) Не

Ако је одговор не, образложити _____

2. Прикупљање података

2.1 Методологија за прикупљање/генерисање података

2.1.1. У оквиру ког истраживачког нацрта су подаци прикупљени?

а) експеримент, навести тип _____ одређивање и моделовање флукса пермеата неуронским мрежама _____

б) корелационо истраживање, навести тип _____

ц) анализа текста, навести тип _____

д) остало, навести шта _____

2.1.2 Навести врсте мерних инструмената или стандарде података специфичних за одређену научну дисциплину (ако постоје).

2.2 Квалитет података и стандарди

2.2.1. Третман недостајућих података

а) Да ли матрица садржи недостајуће податке? Да Не

Ако је одговор да, одговорити на следећа питања:

а) Колики је број недостајућих података? _____

б) Да ли се кориснику матрице препоручује замена недостајућих података? Да Не

в) Ако је одговор да, навести сугестије за третман замене недостајућих података

2.2.2. На који начин је контролисан квалитет података? Описати

Квалитет података је контролисан применом статистичких тестова и одбацивањем екстрема.

2.2.3. На који начин је извршена контрола уноса података у матрицу?

Контрола уноса података у матрицу је изведена поређењем добијених података са литературним подацима

3. Третман података и пратећа документација

3.1. Третман и чување података

3.1.1. Подаци ће бити депоновани у _____ репозиторијум _____.

3.1.2. URL адреса _____

3.1.3. DOI _____

3.1.4. Да ли ће подаци бити у отвореном приступу?

- а) Да
- б) Да, али после ембарга који ће трајати до _____
- в) Не

Ако је одговор не, навести разлог _____

3.1.5. Подаци неће бити депоновани у репозиторијум, али ће бити чувани.

Образложење

3.2 Метаподаци и документација података

3.2.1. Који стандард за метаподатке ће бити примењен? _____

3.2.1. Навести метаподатке на основу којих су подаци депоновани у репозиторијум.

Ако је потребно, навести методе које се користе за преузимање података, аналитичке и процедуралне информације, њихово кодирање, детаљне описе варијабли, записа итд.

3.3 Стратегија и стандарди за чување података

3.3.1. До ког периода ће подаци бити чувани у репозиторијуму? _____

3.3.2. Да ли ће подаци бити депоновани под шифром? Да Не

3.3.3. Да ли ће шифра бити доступна одређеном кругу истраживача? Да Не

3.3.4. Да ли се подаци морају уклонити из отвореног приступа после извесног времена?

Да Не

Образложити

4. Безбедност података и заштита поверљивих информација

Овај одељак МОРА бити попуњен ако ваши подаци укључују личне податке који се односе на учеснике у истраживању. За друга истраживања треба такође размотрити заштиту и сигурност

података.

4.1 Формални стандарди за сигурност информација/података

Истраживачи који спроводе испитивања с људима морају да се придржавају Закона о заштити података о личности (https://www.paragraf.rs/propisi/zakon_o_zastiti_podataka_o_licnosti.html) и одговарајућег институционалног кодекса о академском интегритету.

4.1.2. Да ли је истраживање одобрено од стране етичке комисије? Да Не

Ако је одговор Да, навести датум и назив етичке комисије која је одобрила истраживање

4.1.2. Да ли подаци укључују личне податке учесника у истраживању? Да Не

Ако је одговор да, наведите на који начин сте осигурали поверљивост и сигурност информација везаних за испитанике:

- a) Подаци нису у отвореном приступу
- b) Подаци су анонимизирани
- c) Остало, навести шта

5. Доступност података

5.1. Подаци ће бити

a) јавно доступни

b) доступни само уском кругу истраживача у одређеној научној области

c) затворени

Ако су подаци доступни само уском кругу истраживача, навести под којим условима могу да их користе:

Ако су подаци доступни само уском кругу истраживача, навести на који начин могу приступити подацима:

5.4. Навести лиценцу под којом ће прикупљени подаци бити архивирани.

6. Улоге и одговорност

6.1. Навести име и презиме и мејл адресу власника (аутора) података

Николић Невенка, nikolicnevenka@outlook.com

6.2. Навести име и презиме и мејл адресу особе која одржава матрицу с подацима

Николић Невенка, nikolicnevenka@outlook.com

6.3. Навести име и презиме и мејл адресу особе која омогућује приступ подацима другим истраживачима

Николић Невенка, nikolicnevenka@outlook.com