

Filtriranje signala primjenom dinamičke neuronske mreže u regulaciji istrošenosti reznih alata

Bešić, Sara

Master's thesis / Diplomski rad

2020

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Mechanical Engineering and Naval Architecture / Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:235:685351>

Rights / Prava: [In copyright](#)/[Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2025-01-18**

Repository / Repozitorij:

[Repository of Faculty of Mechanical Engineering and Naval Architecture University of Zagreb](#)



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Sara Bešić

Zagreb, 2020.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Mentor:

Izv. prof. dr. sc. Danko Brezak, dipl. ing.

Student:

Sara Bešić

Zagreb, 2020.

Izjavljujem da sam ovaj rad izradila samostalno koristeći znanja stečena tijekom studija i navedenu literaturu.

Zahvaljujem se na pomoći, strpljenju, savjetima i prenesenom znanju svojem mentoru dr. sc. Danku Brezaku, izv. prof.

Zahvaljujem se svojim najbližima koji su bili uz mene tijekom mog obrazovanja i pružili mi beskrajnu podršku i razumijevanje.

Sara Bešić



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE



Središnje povjerenstvo za završne i diplomske ispite
Povjerenstvo za diplomske radove studija strojarstva za smjerove:
proizvodno inženjerstvo, računalno inženjerstvo, industrijsko inženjerstvo i menadžment,
inženjerstvo materijala te mehatronika i robotika

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje	
Datum:	Prilog:
Klasa: 602 - 04 / 20 - 6 / 3	
Ur. broj: 15 - 1703 - 20 -	

DIPLOMSKI ZADATAK

Student: SARA BEŠIĆ Mat. br.: 0035203598

Naslov rada na hrvatskom jeziku: **Filtriranje signala primjenom dinamičke neuronske mreže u regulaciji istrošenosti reznih alata**

Naslov rada na engleskom jeziku: **Filtering of estimated flank wear widths using recurrent neural network in the tool wear regulation process**

Opis zadatka:

U cilju realizacije robusnih i pouzdanih sustava za regulaciju stupnja istrošenosti reznih alata nužno je provesti filtriranje estimiranih vrijednosti parametara trošenja u povratnoj vezi regulacijske petlje. Kako parametri trošenja ne mogu biti izmjereni za vrijeme obrade, njihove se vrijednosti estimiraju na temelju različitih vrsta snimljenih signala procesa. No, takav oblik estimacije za posljedicu često ima značajno odstupanje od stvarne vrijednosti razmatranog parametra trošenja. Navedeno odstupanje ima negativan utjecaj na generiranje upravljačke veličine čime dolazi do nepotrebnog i štetnog opterećivanja izvršnog člana, tj. glavnog pogona stroja. Stoga će u ovom radu biti potrebno analizirati mogućnost primjene dinamičke neuronske mreže s različitim vrstama IIR i FIR tipova filtara u neuronima skrivenog sloja sa svrhom filtriranja estimiranih vrijednosti parametra trošenja stražnje površine reznog alata.

U radu je potrebno:

1. Izvesti matematičke algoritme unaprijedne i povratne faze učenja dinamičke neuronske mreže za nekoliko različitih dinamika IIR i FIR tipova filtara.
2. Izraditi programsku podršku za sve izvedene algoritme.
3. Generirati skup signala na temelju kojih će se provesti testiranje svih modela mreže.
4. Provesti detaljnu analizu karakteristika rada razmatranih modela mreže s obzirom na kvalitetu filtriranja.
5. Izvesti zaključke rada.

U radu je također potrebno navesti korištenu literaturu i eventualno dobivenu pomoć.

Zadatak zadan:
30. travnja 2020.

Rok predaje rada:
2. srpnja 2020.

Predviđeni datum obrane:
6. srpnja do 10. srpnja 2020.

Zadatak zadao:

prof. dr. sc. Danko Brezak

Predsjednica Povjerenstva:

prof. dr. sc. Biserka Runje

SADRŽAJ

SADRŽAJ	I
POPIS SLIKA	II
POPIS TABLICA.....	III
POPIS OZNAKA	IV
SAŽETAK.....	VII
SUMMARY	VIII
1. UVOD.....	1
1.1. Struktura rada	2
2. NADZOR ISTROŠENOSTI REZNIH ALATA	4
2.1. Pristupi mjerenju istrošenosti reznog alata	4
2.2. Adaptivno vođenje alatnog stroja	5
2.3. Koren – Lenzov model trošenja	6
3. FIR I IIR FILTRI.....	8
3.1. Signali	8
3.2. Digitalna obrada signala.....	8
3.3. Filtriranje signala	9
3.3.1. Odabir vrste filtra	10
3.4. FIR filtar.....	11
3.5. IIR filtar.....	12
3.6. Prednosti i nedostaci IIR i FIR filtra	13
4. UMJETNE NEURONSKE MREŽE	14
4.1. Dinamička neuronska mreža u ulozi filtra	15
4.2. Struktura mreže	16
4.3. Algoritam učenja mreže	19
4.3.1. Unaprijedna faza učenja.....	19
4.3.2. Povratna faza učenja	20
4.3.3. Ocjena uspješnosti algoritma	24
5. ANALIZA REZULTATA	25
5.1. Faza učenja.....	25
5.2. Faza testiranja	28
6. ZAKLJUČAK.....	34
LITERATURA.....	36

POPIS SLIKA

Slika 1. Regulacijski model obradnog procesa prema postojanosti reznog alata [3].....	5
Slika 2. Simulirane krivulje trošenja za zadane parametre obrade	7
Slika 3. Blokovska shema FIR filtra [11].....	11
Slika 4. Blokovska shema IIR filtra [11]	12
Slika 5. Dinamički neuron s ugrađenim IIR filtrom 2. reda	16
Slika 6. Dinamički neuron s ugrađenim FIR filtrom 2. reda.....	16
Slika 7. Gaussova aktivacijska funkcija.....	17
Slika 8. Struktura DNM s Gaussovom aktivacijskom funkcijom [3]	18
Slika 9. Krivulja NRMS faktora za IIR filter 2. reda (za estimacijsku pogrešku 0,1 mm)	27
Slika 10. Odziv mreže na datoteku učenja (za estimacijsku pogrešku 0,05 mm)	27
Slika 11. Odziv mreže na datoteku učenja (za estimacijsku pogrešku 0,1 mm)	28
Slika 12. Odziv mreže na test 1	31
Slika 13. Odziv mreže na test 2.....	31
Slika 14. Odziv mreže na test 3.....	32
Slika 15. Odziv mreže na test 4.....	32
Slika 16. Odziv mreže na test 5.....	32
Slika 17. Odziv mreže na test 6.....	33
Slika 18. Odziv mreže na test 7.....	33

POPIS TABLICA

Tablica 1. Rezultati učenja mreža za podatke s estimacijskom pogreškom 0,05 mm	26
Tablica 2. Rezultati učenja mreža za podatke s estimacijskom pogreškom 0,1 mm	26
Tablica 3. Parametri testova	28
Tablica 4. Rezultati učenja i testiranja IIR filtra za grešku estimacije 0,05 mm	29
Tablica 5. Rezultati učenja i testiranja FIR filtra za grešku estimacije 0,05 mm.....	29
Tablica 6. Rezultati učenja i testiranja IIR filtra za grešku estimacije 0,1 mm	30
Tablica 7. Rezultati učenja i testiranja FIR filtra za grešku estimacije 0,1 mm.....	30

POPIS OZNAKA

Oznaka	Jedinica	Opis
A_j	-	nazivnik prijenosne funkcije dinamičkog člana dinamičkog neurona diskretne forme
a_{ij}	-	i-ti koeficijent nazivnika prijenosne funkcije dinamičkog člana j-og dinamičkog neurona
a_p	mm	dubina rezanja
B_j	-	brojnik prijenosne funkcije dinamičkog člana dinamičkog neurona diskretne forme
b_{ij}	-	i-ti koeficijent brojnika prijenosne funkcije dinamičkog člana j-og dinamičkog neurona
d_k	-	željena vrijednost k-og izlaza neuronske mreže
E	-	funkcija cilja (suma kvadrata pogrešaka)
f_z	mm/okr	posmak alata
I	-	broj neurona ulaznog sloja mreže
J	-	broj neurona sakrivenog sloja mreže
K	-	broj neurona izlaznog sloja mreže, broj centara (neurona skrivenog sloja)
K_p	-	pojačanje sustava
N	-	broj parova ulazno-izlaznih vrijednosti seta učenja
n	-	broj značajki, broj komponenti ulaznog vektora, broj neurona ulaznog sloja
NRMS	-	normalizirani korijen srednje kvadratne pogreške - mjera točnosti

net_{Hj}	-	vrijednost funkcije sume j-og neurona sakrivenog sloja
net_{Ok}	-	vrijednost funkcije sume k-og neurona izlaznog sloja
O_k	-	k-ti izlaz neuronske mreže
RMS	-	korijen srednje kvadratne pogreške
$t_{t,kon}$	min	željeno vrijeme rezanja
VB	mm	parametar trošenja stražnje površine reznog alata
VB_{kon}	mm	željeni iznos parametra trošenja stražnje površine reznog alata
v_c	m/min	brzina rezanja
v_{ji}	-	težinski koeficijent veze između j-og neurona sakrivenog sloja i i-tog neurona ulaznog sloja
w_{kj}	-	težinski koeficijent veze između k-og neurona izlaznog sloja i j-tog neurona sakrivenog sloja
\bar{y}	-	izlaz dinamičkog člana dinamičkog neurona i ulaz aktivacijske funkcije dinamičkog neurona
$\bar{y}(n-i)$	-	izlaz dinamičkog člana dinamičkog neurona u (n-i) koraku
y_j	-	vrijednost izlaza j-og neurona sakrivenog sloja
Z_i	-	i-ti ulaz neuronske mreže
$z^{-i}[net(n)]$	-	operator linearnog pomaka
ϑ	-	parametar učenja (težinski koeficijent, dinamički koeficijent)
$\vartheta(n)$	-	trenutna vrijednost parametra učenja
$\vartheta(n+1)$	-	nova vrijednost parametra učenja
$\Delta\vartheta(n)$	-	tekuća promjena parametra učenja

α	-	vrijednost momentuma
δ	-	parametar algoritma povratnog prostiranja pogreške
δ_i^I	-	impulsni poremećaj
δ_i^V	-	varijabilni poremećaj
δ_{ok}	-	parametar algoritma povratnog prostiranja pogreške izlaznog sloja
γ	-	aktivacijska funkcija neurona
η	-	koeficijent brzine učenja
σ_{dn}	-	standardna devijacija željenih vrijednosti izlaza mreže
∇E	-	gradijent pogreške

SAŽETAK

Adaptivno vođenje alatnih strojeva prema istrošenosti reznog alata se, zbog nemogućnosti direktnog mjerenja stanja oštrice tijekom procesa obrade, oslanja na indirektno mjerenje signala povezanih s trošenjem i njihovu estimaciju kako bi se dobile informacije o stanju rezne oštrice u realnom vremenu. Unutar snimljenih signala obuhvaćeni su i oni signali koji nisu izravno povezani s procesom trošenja, a javljaju se prilikom obrade odvajanjem čestica. Pogreška estimacije neizbježna je u procesu regulacije. Kako bi se smanjile neželjene smetnje, poremećaji i šumovi, signale je potrebno obraditi, odnosno filtrirati. Filtriranjem se nepoželjni utjecaji potiskuju na prihvatljivu razinu, odnosno smanjuje se pogreška estimacije i njezin utjecaj u regulacijskom krugu nadzora obradnog stroja prema istrošenosti reznog alata. U ovom radu korištene su dvije vrste filtra, FIR i IIR filtar. Oba filtra korištena su u tri modifikacije kao filtri 2., 4. i 6. reda. Realizacija filtara ostvarena je putem dinamičke neuronske mreže. Cilj je usporediti rezultate obrade signala svih šest filtara te izvesti zaključak utječe li vrsta filtra i njegov red na uspješnost potiskivanja poremećaja u signalu obrade. Signal obrade predstavljaju eksperimentalno prikupljeni podaci iz procesa obrade tokarenjem.

Ključne riječi: nadzor istrošenosti reznog alata, šum, obrada signala, filtriranje, FIR filtar, IIR filtar, dinamička neuronska mreža

SUMMARY

Due to the impossibility of directly measuring the condition of a tool during the machining process, adaptive machine control for maintaining the tool wear rate in the predefined cutting time relies on measuring signals that are related to tool wear. Those signals are then estimated in real-time. Based on that estimation, tool wear condition is predicted. Measured signals also include some signals that are not related to tool wear, but they occur during the machining process. In regulation the estimation error is inevitable. To reduce the effect of different kinds of interferences, disturbances and noises, signals are processed. Filtering suppresses interferences to an acceptable level, i.e. it reduces estimation error and its influence in the tool wear regulation process. This paper reviews two types of filters: FIR and IIR and their modifications as filters of 2nd, 4th and 6th order. Filters are structured using a recurrent neural network algorithm. The objective of this paper is to analyse and compare the results of mentioned filters and to draw a conclusion if the filter type and the filter order affect filter's performance. Experimentally collected data from the turning process are used as input signals for filters.

Key words: tool wear regulation process, noise, signal processing, filtering, FIR filter, IIR filter, recurrent neural network

1. UVOD

U proizvodnji, promjena rezne oštrice alata u odgovarajuće vrijeme, kada alat više ne može ispravno izvršavati obradu odvajanjem čestica, je od ključne važnosti. Praćenje istrošenosti reznog alata u realnom vremenu temeljni je zahtjev moderne industrije koja teži visokoj produktivnosti obradnih procesa i izvrsnoj kvaliteti proizvoda [1]. Vođenje alatnog stroja prema istrošenosti reznog alata predmet je brojnih istraživanja današnjice. Usprkos naporima znanstvenika još uvijek nije pronađeno rješenje koje sa sobom ne nosi određene probleme i ograničenja. Stoga adaptivna regulacija alatnih strojeva danas još uvijek nije moguća u potpunosti. Razvoj adaptivne regulacije slijedeći je korak u napretku moderne proizvodnje.

Svrha regulacije alatnog stroja prema istrošenosti reznog alata je prilagodba parametara obrade kako bi se postigao dulji vijek trajanja alata i smanjila vjerojatnost loma alata kod neočekivanog naglog trošenja za vrijeme obrade, što može uzrokovati oštećenje stroja i/ili obratka. Ideja je aktivno djelovati na proces obrade i izmjenu alata.

Direktno mjerenje trošenja rezne oštrice alata tijekom obrade nije moguće budući da direktne metode mjere istrošenost alata kada on nije u zahvatu s obratkom. Primjenom indirektnih metoda otvara se mogućnost nadzora istrošenosti za vrijeme obrade u realnom vremenu. Indirektnim mjerenjem prikupljaju se različite vrste procesnih signala koji su povezani s parametrom trošenja koji se prati. U ovom slučaju taj parametar predstavlja istrošenost stražnje površine alata. Temeljem prikupljenih podataka procjenjuje se stvarna vrijednost odabranog parametra.

Drugim riječima, prikupljeni podaci iz procesa obrade šalju se u estimator stupnja istrošenosti stražnje površine alata. Prilikom estimacije parametra trošenja nastaju neizbježne i često vrlo izražene pogreške estimacije. Unutar prikupljenih signala također se nalaze i brojni poremećaji obradnog procesa koji nisu nužno vezani za trošenje alata. Podaci s estimatora idu u regulator postojanosti rezne oštrice. Ako regulator dobije pogrešnu informaciju o stanju rezne oštrice, može ili prerano zaustaviti proces čime se gubi produktivnost ili ne zaustaviti proces na vrijeme, čime se gubi smisao adaptivnog vođenja prema istrošenosti reznog alata.

Šumovi i poremećaji unutar signala otežavaju mogućnost adaptivnog vođenja, stoga je filter izrazito važan dio regulacijskog kruga. Svrha filtriranja je smanjenje utjecaja šuma na izvršnu veličinu regulatora. Postavlja se između estimatora i regulatora na način da mu ulaznu veličinu predstavljaju zašumljeni signali s estimatora, a na svom izlazu daje filtrirani signal koji predstavlja ulaz u regulator. Osim pogreške estimatora, svrha filtra je i da prigušuje frekvencije

signala koji nisu vezani za trošenje alata, a čine sastavni dio procesa obrade. Bez filtriranja šumovi i poremećaji bi se putem povratne veze vraćali preko regulatora u upravljački krug i izazivali bi nepravilnosti u radu obradnog stroja koje bi se očitovale u izraženim oscilacijama upravljačke veličine, odnosno brzine rezanja.

Rastući trend digitalne obrade signala ukazuje na to će ona uvelike utjecati na razvoj znanosti 21. stoljeća. Jedno od glavnih područja primjene digitalne obrade signala su digitalni filtri, čije performanse u većini slučajeva nadilaze analogne filtre [2]. Dvije su vrste digitalnih filtara: nerekurzivni i rekurzivni filtri.

Umjetne neuronske mreže široko su područje istraživanja. Njihova glavna odlika je paralelno procesuiranje podataka i mogućnost dobrog praćenja i modeliranja nelinearnih procesa kao što je trošenje reznog alata. Trošenje je također proces dijelom stohastičke prirode što se očituje u pojavi raznih poremećaja i šumova u snimljenim signalima za vrijeme procesa obrade. Važna karakteristika neuronskih mreža je prigušivanje šumova i smetnji unutar signala.

Spojem digitalne obrade signala i umjetnih neuronskih mreža dobiven je algoritam koji je pogodan za konstrukciju filtra potrebnog u regulacijskom krugu nadzora alatnog stroja prema istrošenosti reznog alata. Obje vrste digitalnih filtra implementirane su unutar dinamičke neuronske mreže. Zbog nemogućnosti ispitivanja algoritama adaptivnog vođenja u stvarnim uvjetima obrade, realni proces zamijenjen je analitičkim modelom dinamike trošenja (Koren–Lenzov model trošenja). Parametri modela određeni su temeljem eksperimentalno prikupljenih podataka [3]. Kako bi se što više približio realnim uvjetima obrade, u model su implementirani poremećaji i pogreške estimacije. Struktura filtra određena je na temelju srednjih krivulja trošenja koje su generirane pomoću spomenutog modela.

1.1. Struktura rada

U drugom poglavlju opisana je funkcija i svrha nadzora alatnog stroja prema istrošenosti reznog alata. Objasnjene su metode mjerenja signala iz procesa obrade te uloga i položaj filtra unutar regulacijskog kruga.

U trećem poglavlju ukratko je razmotrena digitalna obrada signala. Detaljno je opisano filtriranje signala. Izloženi su filtri (FIR i IIR) koji će biti korišteni za obradu signala.

Četvrto poglavlje odnosi se na umjetne neuronske mreže. Naglasak je stavljen na dinamičku neuronsku mrežu u ulozi filtra. Detaljniji pregled umjetnih neuronskih mreža izložen je u [4]. Dan je algoritam dinamičke neuronske mreže s ugrađenim FIR i IIR filtrima.

Peto poglavlje razmatra praktičan dio rada. Provedena je analiza sa svrhom utvrđivanja utječe li red filtra i drugačija dinamika na uspješnost filtriranja signala estimatora.

U posljednjem poglavlju na temelju dobivenih rezultata iznijeti su zaključci rada.

2. NADZOR ISTROŠENOSTI REZNIH ALATA

Trošenje rezne oštrice alata neizbježan je proces prilikom procesa obrade materijala/odvajanjem. Nastaje kao posljedica raznih opterećenja kojima je alat izložen prilikom obrade [5]. Proces trošenja i uz njega povezani fenomeni izrazito su složeni te je nadzor istih izrazito zahtjevan postupak [6]. Istrošenost reznih alata predstavlja uzrok najvećih problema kod obradnih sustava kao što su loša kvaliteta obrađene površine, pojava škarta i loša produktivnost procesa obrade.

Svrha nadzora obradnih strojeva i procesa je kontinuirano praćenje i nadziranje rada stroja, alata i stanja obratka tijekom same obrade, a s ciljem zadovoljavanja niza zahtjeva u proizvodnji. Zahtjevi su brojni, a neki od njih su: visoka produktivnost, robusnost proizvodnog procesa, kvaliteta, sigurnost, pouzdanost, preciznost, itd.

2.1. Pristupi mjerenju istrošenosti reznog alata

Prema [3] razlikuju se dvije metode mjerenja stupnja istrošenosti alata:

- Direktna metoda
- Indirektna metoda

Direktnim pristupom izravno se iz mjerenih signala dobivaju informacije o parametrima koji se nadziru. Željene parametre procesa je doista moguće snimiti. Istrošenost alata može se direktno mjeriti tek kada alat nije u zahvatu, odnosno nakon prestanka obrade. Zato se ova metoda još naziva i „*off-line*“ metoda. Očiti nedostatak ovakvog pristupa nadzoru je kašnjenje u procjeni stupnja istrošenosti alata. Nedostatke još predstavljaju i visoka cijena te komplicirana instalacija budući da se mjerenje parametara najčešće vrši pomoću vizijskih sustava, ali i mogućnost utjecaja elemenata obrade kao što su odvojene čestice ili SHIP na procjenu istrošenosti rezne oštrice.

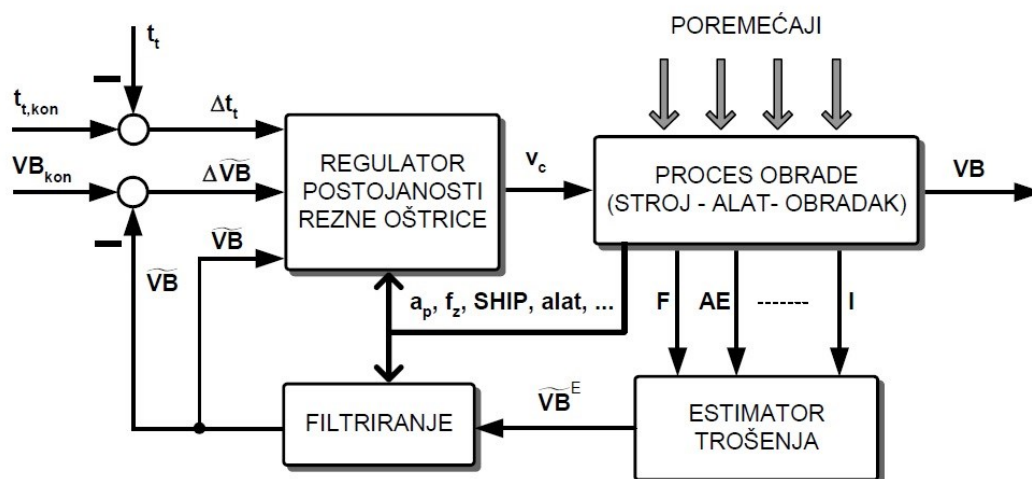
Suprotno tome, indirektnim pristupom istrošenost rezne oštrice može se procijeniti na temelju signala snimljenih za vrijeme procesa obrade. Metoda se oslanja na senzore kojima se mjere različiti signali tijekom obrade vezani za istrošenost reznog alata. Iz takvih signala nužno je izdvojiti značajke pomoću kojih će se kasnije procijeniti stupanj istrošenosti. Metoda se još naziva i „*on-line*“ metoda jer otvara mogućnost praćenja stanja oštrice u realnom vremenu što je preduvjet razvoju adaptivnog vođenja alatnog stroja [3].

Mjereni signali, dobiveni iz procesa obrade pomoću senzora, sadrže različite poremećaje i šumove, ali i korisne informacije vezane za promatrani proces [6]. Obrada signala i filtriranje nužan su korak kako bi se istaknule korisne informacije koje signal sadrži te iz njih dobile značajke procesa trošenja. Iz skupa značajki izabiru se one značajke koje najviše koreliraju s parametrom koji se nadzire, u ovom slučaju s istrošenošću alata.

2.2. Adaptivno vođenje alatnog stroja

Nadzor istrošenosti reznih alata može uvelike utjecati na kvalitetu proizvoda, sigurnost i produktivnost obradnog procesa, stoga predstavlja jedan od osnovnih elemenata regulacije alatnih strojeva [7]. Implementacijom sustava za nadzor trošenja unutar regulacijskog kruga obradnog stroja povećava se razina automatizacije stroja i omogućava se razvoj adaptivne regulacije.

Adaptivno vođenje alatnog stroja prema postojanosti oštrice reznog alata predstavlja nadogradnju procesu kontinuiranog praćenja stupnja istrošenosti reznog alata [3]. Ono što razlikuje adaptivno vođenje u odnosu na klasične metode nadzora i servoregulacije pogonskih osi stroja je mogućnost prilagodbe parametra obrade u stvarnom vremenu. Razvoj ovakve vrste adaptivnog vođenja tek je u začetcima budući da ne postoje industrijska rješenja u pogledu robusne, pouzdane i precizne kontinuirane estimacije parametara trošenja.



Slika 1. Regulacijski model obradnog procesa prema postojanosti reznog alata [3]

Regulacijski krug shematski prikazan slikom 1. prikazuje ulogu filtra u procesu adaptivnog vođenja. Struktura estimatora trošenja konfigurira se korištenjem nekoliko vrsta procesnih signala snimljenih u različitim očekivanim uvjetima obrade. Estimirane se vrijednosti zatim dodatno filtriraju kako bi se prigušio utjecaj estimacijske pogreške. Zatim se primjenom adekvatnog regulacijskog algoritma generira potrebna brzina rezanja na temelju procijenjenih filtriranih iznosa parametra trošenja, razlike između trenutnog i željenog stanja alata te svih ostalih dodatnih ulaznih parametara regulatora [3]. Detaljan prikaz razvoja sustava za nadzor trošenja reznih alata metodama adaptivnog vođenja, kao i razvoj hibridnog estimatora izloženi su u izvorima [3, 6, 7].

Parametar trošenja temeljem kojeg će se provoditi regulacija, odnosno adaptivno vođenje prema postojanosti rezne oštrice je širina trošenja stražnje površine alata (VB). Ovaj parametar regulira se tako što se parametar VB ograničava na svoju maksimalnu vrijednost VB_{kon} u određenom vremenu rezanju $t_{t, kon}$. Na se način povećava produktivnost čitavog procesa obrade, ali i iskoristivost reznog alata u zadanom ciklusu izmjene [3].

2.3. Koren – Lenzov model trošenja


Ispitivanje algoritama adaptivnog vođenja u stvarnim uvjetima obrade nije moguće, zbog toga se istraživanja provode na matematičkim modelima procesa obrade. Analitički model trošenja definiran je temeljem eksperimentalno prikupljenih podataka. Pomoću njega je, uz implementaciju funkcija poremećaja, modelirana dinamika trošenja reznog alata u regulacijskom krugu. Uloga modela je približiti simulirane uvjete rezanja realnima. U stvarnim uvjetima očekuje se strukturiranje algoritama vođenja s obzirom na dinamiku procesa trošenja određenu isključivo značajkama trošenja iz snimanih signala procesa [3].

U ovom radu biti će korišten Koren-Lenzov model trošenja. Koren-Lenzov model trošenja [8] daje vezu između parametara procesa i trošenja alata. To je eksperimentalno postavljen model koji je zasnovan na kombinaciji dvaju dominantnih mehanizama trošenja, mehaničkom i toplinskom. Parametri modela određeni su na temelju eksperimentalno prikupljenih podataka u procesu obrade tokarenjem [3].

Za parametra trošenja odabrana je širina stražnje površine alata VB jer je najdominantniji parametar trošenja. Estimacijske pogreške kao i drugi poremećaji obradnog procesa, također su dodani modelu kako bi se simulirana dinamika trošenja dodatno približila stvarnim uvjetima obrade.

Razmatrane su tri skupine poremećaja: impulsni, varijabilni i estimacijski. Impulsni su poremećaji vezani uz pojavu naglog povećanja intenziteta trošenja izazvanog manjim djelomičnim krhanjima oštrice alata koja nisu tolika da bi se moglo govoriti o potpunom lomu oštrice. Varijabilni poremećaji podrazumijevaju odstupanja koja nastaju zbog lokalnih promjenjivih mehaničkih svojstava obratka/alata ili ostalih uvjeta obrade. U treću skupinu poremećaja spadaju neizbježne i često vrlo izražene pogreške koje nastaju pri estimaciji parametara trošenja [3].

Pomoću analitičkog modela trošenja, koji je strukturiran primjenom eksperimentalno prikupljenih podataka, generirane su srednje krivulje trošenja na temelju kojih je formirana struktura filtra. Krivulje prikazane slikom 2. simulirane su za sljedeće parametre obrade: $a_p = 2,5$ mm, $f = 0,35$ mm/okr i $v_c = 100 - 300$ m/min.



Slika 2. Simulirane krivulje trošenja za zadane parametre obrade

Krivulje su zašumljene estimacijskom pogreškom od 0,05 mm i 0,1 mm u svrhu simulacije realnih uvjeta.

3. FIR I IIR FILTRI

3.1. Signali

Signal je prikaz povezanosti jednog parametra s drugim parametrom [9]. Signal je nositelj informacija. Promjenljiv je u vremenu i može se mjeriti. Dvije su osnovne podjele signala prema [10].

Prema prirodi vremenske varijable signali se dijele na:

- Vremenski kontinuirane
- Vremenski diskretne

Vremenski diskretan signal dobiva se uzrokovanjem kontinuiranog signala.

Prema prirodi amplitude razlikuju se:

- Analogni signali
- Digitalni signali

Analogni signal je vremenski kontinuiran što znači da prati kontinuiranu promjenu signala u vremenu. Digitalni signal se još naziva i binarni signal. On može poprimiti samo dvije vrijednosti signala, a to su 0 za visoko („on“) stanje i 1 za nisko („off“) stanje [10]. Digitalni signal također je kontinuiran u vremenu, ali je diskretan po amplitudi za razliku od analognog koji je kontinuiran i po amplitudi i u vremenu.

3.2. Digitalna obrada signala

Svrha obrade signala je izdvojiti korisne informacije od svih informacija koje signal prenosi. Metoda kojom će se taj proces odvijati ovisi o vrsti signala i prirodi informacija koje signal prenosi, odnosno o vrsti procesa čiji se signali obrađuju te željenim podacima iz signala. Općenito, obrada signala bavi se matematičkim prikazom signala i algoritamskim operacijama koje se na njemu provode u svrhu izdvajanja iz njega potrebnih informacija [11].

Digitalna obrada signala (DSP) je jedna od najmoćnijih tehnologija koja će uvelike utjecati i oblikovati znanost i inženjerstvo 21. stoljeća. DSP se razlikuje od ostalih područja računalne tehnologije prema jedinstvenoj vrsti podataka koje koristi, a to su signali. U većini slučajeva ti signali su senzorski podaci iz stvarnog svijeta: seizmičke vibracije, vizualne slike, zvučni valovi itd. DSP se, u matematici, algoritmima i tehnici koristi za manipuliranje tih signala nakon što su pretvoreni u digitalni oblik [9]. Dakle, DSP se bavi digitalnim signalima i uporabom digitalnih sustava za analizu, izmjenu, pohranu ili izdvajanje informacija iz signala.

Provedena su brojna istraživanja s ciljem razvoja DSP algoritama i sustava za primjenu u stvarnom svijetu. Posljednjih godina, nagli napredak digitalnih tehnologija podržavao je implementaciju sofisticiranih DSP algoritama za primjenu u realnom vremenu. DSP se sada koristi ne samo u područjima gdje su ranije bile korištene analogne metode, već i tamo gdje je primjena analognih tehnika vrlo teška ili nemoguća. Mnogo je prednosti upotrebe digitalnih tehnika za obradu signala umjesto tradicionalnih analognih uređaja, poput pojačala, modulatora i filtera. DSP algoritmi se mogu razviti, analizirati i simulirati koristeći programske jezike visoke razine i softverske alate visoke razine poput C / C ++ i MATLAB (matrični laboratorij). Učinkovitost algoritama može se provjeriti korištenjem jeftinih računala opće namjene. Prema tome, DSP sustav je relativno jednostavan za projektiranje, razvoj, analizu, simulaciju, testiranje i održavanje [12]. Budućnost DSP-a je zamijeniti hardver sa softverom.

Općenito, jedna od najraširenijih metoda obrade signala je filtriranje, stoga nije začuđujuće što je primarna primjena DSP-a smanjivanje smetnji, šumova i ostalih nepoželjnih komponenti u signalima koji se obrađuju. Veliki dio DSP-a orijentiran je na oblikovanje digitalnih filtra.

Digitalni filter izvodi numeričke izračune, odnosno matematičke operacije na uzorkovanim vrijednostima signala kako bi naglasio ili prigušio određene dijelove signala. Digitalni filter je matematički algoritam implementiran u hardware, firmware i / ili software za postizanje ciljeva filtriranja [12]. Digitalni filtri vrlo su važan dio DSP-a. Njihovi iznimni rezultati jedan su od ključnih razloga što je DSP postao toliko popularan.

Dvije su glavne vrste digitalnih filtra: rekurzivni i nerekurzivni filtri, odnosno IIR i FIR filtri koji će biti izloženi u nastavku ovog poglavlja.

3.3. Filtriranje signala

Filtar ima dvije namjene: odvajanje signala i obnavljanje signala. Odvajanje signala je potrebno kada je signal kontaminiran smetnjama, bukom ili drugim signalima koji nisu vezani za promatrani proces. Također, odvajanje signala može se koristiti i kako bi se određene komponente signala pojedinačno analizirale. Obnavljanje signala koristi se kada je signal na neki način izobličen [9].

Veliki broj industrijskih mjernih sustava korištenih u nadzoru trošenja reznih alata isporučuje se s već ugrađenim filtrom signala. Senzori se na tržište isporučuju zajedno s pratećom elektronikom koja sadrži već izvedene filtre.

Filtar ograničava mjerno područje senzora. Međutim, nije dovoljno filtrirati signal samo unutar mjernog područja senzora jer se i unutar njega mogu pojaviti šumovi. Šumovi su neželjeni signali koji nisu vezani za parametre procesa koji se nadzire, odnosno čiji izvor nije vezan uz dio procesa koji se nadzire. Takve neželjene signale nužno je identificirati i filtrirati kako bi se istaknula potrebna informacija tj. smanjio šum.

Pomoću filtra najčešće se ograničava frekvencijski pojas na područje u kojem senzor može kvalitetno mjeriti. Osim osnovnog filtriranja signala na mjerno područje senzora mogu se provesti dodatna filtriranja. Ona se provode unutar radnog područja senzora kako bi se prigušili već spomenuti šumovi.

3.3.1. Odabir vrste filtra

Filtri mogu biti hardverski realizirani, implementirani u mjernu opremu kao sklopovi ili softverski realizirani putem računala, odnosno programske podrške u fazi dodatnog filtriranja kao matematički algoritmi. Ovako definirani filtri omogućavaju propuštanje signala točno određenih frekvencija dok su ostale frekvencije prigušene. Prema frekvenciji koju propuštaju filtre dijelimo na:

- niskopropusne,
- pojasnpropusne
- visokopropusne.


Niskopropusni filtri propuštaju signale do određene frekvencije, a nakon te iste frekvencije ih prigušuju. S druge strane, visokopropusni filtri ne propuštaju signale do određene frekvencije, a nakon nje propuštaju sve signale. Pojasnpropusni filter propušta signale samo unutar definiranog pojasa [13].

Postupak filtriranja nije jednoznačno definiran. S jednom vrstom filtra ne možemo prigušiti svaku vrstu šuma. To znači da je vrsta filtra vezana za individualne karakteristike određenog procesa, tj. ovisi o dinamici promatranog sustava. U kontekstu alatnog stroja vrsta filtra ovisi o alatu koji se koristi, vrsti stroja i njegovim karakteristikama, materijalu i veličini obratka, parametrima obrade i ostalim uvjetima obrade. Određivanjem individualnih karakteristika filtra izbjegava se prigušivanje onih dijelova signala koji su nositelji potrebnih informacija o stanju alata, obratka i stroja [13].

Dinamiku filtra odrediti će parametri samog filtra, odnosno vrijednosti njegovih koeficijenata. Odabir vrste filtra ovisiti će podjednako o njegovoj brzini i traženoj kvaliteti izlaznog signala.

3.4. FIR filter

Digitalni filtri mogu se implementirati na dva načina. Filtri implementirani konvolucijom su filtri koji imaju konačni impulsni odziv, odnosno to su FIR filtri. Nazivaju se još i nerekurzivnim, jer njihov izlaz ovisi isključivo o trenutnim i prošlim vrijednostima ulaza (slika 3.). FIR filtri su uvijek stabilni, jer nemaju povratnu vezu s prošlim izlaza.



Slika 3. Blokova shema FIR filtra [11]

$$y(n) = b_0x(n) + b_1x(n-1) + b_2x(n-2) + \dots + b_Lx(n-L) \quad (3.1)$$


$$y(n) = \sum_{l=0}^L b_lx(n-l) \quad (3.2)$$

Red nerekurzivnog digitalnog filtra predstavlja broj prethodnih ulaza koji su korišteni za izračunavanje trenutnog izlaza. Konstante $b_0, b_1, b_2, \dots, b_l$ koje se pojavljuju u ovim jednadžbama nazivaju se koeficijenti filtra. Upravo vrijednosti koeficijenata definiraju karakteristike određenog filtra. Koeficijent b_0 vezan je za trenutni ulaz koji se obrađuje dok su ostali koeficijenti vezani za prethodne ulaze u filter u koracima $n-1$, gdje je $l = 1, 2, 3, \dots, L$.

Jednadžbe 3.1 i 3.2 [12] zapravo ukazuju na to da će vrijednost izlaza ovog filtra (filtrirani signal) u koraku n ovisiti o vrijednostima nefiltriranog signala na ulasku u filter u koracima $n, n-1, n-2, \dots, n-L$, ovisno o tome kojeg je reda filter, te o vrijednostima pripadajućih parametara filtra $b_0, b_1, b_2, \dots, b_L$.

3.5. IIR filtar

Rekurzivni ili IIR filtar je filtar s beskonačnim impulsnim odzivom. Ova vrsta digitalnih filtara implementirana je rekurzijom. Odziv na impuls se naziva beskonačnim, jer ovaj filtar u svojoj strukturi (slika 4.) sadrži povratnu vezu. Povratnu vezu ostvaruje tako što prilikom računanja trenutnog izlaza koristi vrijednosti prethodno izračunatih izlaznih vrijednosti, uz vrijednosti trenutnog i prethodnih ulaza kao i FIR filtar.



Slika 4. Blokowska shema IIR filtra [11]

$$y(n) = b_0x(n) + b_1x(n-1) + b_2x(n-1) + \dots + b_Lx(n-L) - a_1y(n-1) - \dots - a_Mx(n-M) \quad (3.3)$$

$$y(n) = \sum_{l=0}^L b_lx(n-l) - \sum_{m=1}^M a_my(n-m) \quad (3.4)$$

Red rekurzivnog filtra najveći je broj prethodnih ulaznih ili izlaznih vrijednosti potreban za računanje trenutnog izlaza. Dok FIR filtar teoretski može biti nultog reda, kod IIR filtra to nije moguće te on mora biti barem prvog reda. IIR filtar nultog reda zapravo je FIR filtar.

Sukladno jednadžbama 3.3 i 3.4 [12] očito je da će filtrirani signal u koraku n ovisiti o istim parametrima kao i kod FIR filtra, ali će se još dodatno signal s izlaza vraćati na ulaz filtra. Dakle, izlazni signal u koraku n dodatno će ovisiti o vrijednostima filtriranih signala u koracima $n-1, n-2, \dots, n-M$ i o parametrima, odnosno koeficijentima filtra koje se vežu uz te vrijednosti, a to su a_1, a_2, \dots, a_2 .

3.6. Prednosti i nedostaci IIR i FIR filtra

Glavna prednost IIR digitalnih filtra, u usporedbi s FIR digitalnim filtrom, je u tome što su računski učinkoviti. Mogu postići zadanu karakteristiku filtriranja koristeći manje memorije i s manje računanja. Teže ih je za programirati, ali su jeftiniji. Nedostatak rekurzivne realizacije je taj što programer mora obratiti posebnu pažnju na stabilnost, parazitne pojave i faznu nelinearnost [14]. IIR filtri osjetljiviji su na probleme računalne aritmetike kao što su npr. šumovi. To je izravna posljedica povratne veze, kada izlaz nije dovoljno dobro izračunat u sebi nosi grešku koja se vraća u filter i multiplicira.

4. UMJETNE NEURONSKE MREŽE

Umjetne neuronske mreže nastale su, kao i većina tehničkih sustava, temeljem pokušaja oponašanja prirodnog sustava, odnosno, u ovom slučaju, načina rada ljudskog mozga. Analogno ljudskom mozgu, umjetne neuronske mreže sastoje se od slojeva neurona koji su međusobno povezani sinapsama, koje u slučaju neuronske mreže predstavljaju težinski koeficijenti. Uobičajeno se mreža sastoji od ulaznog i izlaznog sloja između kojih se nalazi jedan ili više skrivenih slojeva [15]. Umjetne neuronske mreže međusobno se razlikuju po strukturi veza između neurona i neurona s okruženjem mreže, te po metodologiji određivanja intenziteta tih veza (određivanja težina mreže), što predstavlja proces učenja mreže [4].

Učenje mreže može se odvijati iterativno ili jednom koraku te s učiteljem, odnosno bez njega. Supervizorno učenje zahtjeva vanjskog učitelja koji korigira mrežu sve dok ne dobije željeno ponašanje. Kod nesupervizornog učenja mreža se sama organizira. Nakon procesa učenja slijedi testiranje mreže. U procesu testiranja ne mijenjaju se parametri učenja.

Prema protoku signala razlikuju se unaprijedne i povratne neuronske mreže. Unaprijedne mreže karakterizira protok signala kroz slojeve u jednom smjeru, od ulaza prema izlazu mreže. S druge strane, povratne mreže u svojoj strukturi sadrže barem jednu povratnu petlju. Testiranjem se ocjenjuje sposobnost mreže da daje zadovoljavajuće izlaze i za podatke s kojima nije učena [4].

Iz aspekta upravljanja i regulacije, umjetne neuronske mreže mogu se koristiti za:

- Modeliranje dinamičkih sustava
- Identifikaciju procesa
- Adaptivno upravljanje
- Vođenje robota
- Implementaciju neizrazite logike
- Upravljanje u realnom vremenu [13].

Umjetne neuronske mreže su najrašireniji i najčešće korišten oblik računalne inteligencije. Većina obradnih procesa ima složenu i nepredvidivu prirodu zbog vremenski promjenjivih parametara, ali i različitih smetnji. Posljednjih godina, pojavio se značajan interes za uporabom neuronskih mreža u svrhu nadzora i regulacije. Neuronska mreža uči korelacije između ulaza i željenih izlaza mreže i na temelju njih generira nove izlaze, smanjujući razliku

između željenih i dobivenih izlaza. Kada je mreža dovoljno dobro istrenirana ona je sposobna generirati odgovarajuće izlaze kao odziv na nove ulazne podatke. Razlog tomu su dobra generalizacijska svojstva mreže zbog kojih su se neuronske mreže pokazale kao izvrstan alat u području nadzora i regulacije obradnih procesa [16].

U prethodnim poglavljima pojašnjeno je zašto je istrošenost reznog alata jedan od najvećih problema proizvodnog procesa. Neuronska mreža na temelju podataka iz procesa može odrediti stanje rezne oštrice, predvidjeti trajanje reznog alata i moguć lom istog u stvarnom vremenu.

Važna odlika UNM je brzo i paralelno procesiranje velike količine podataka, što omogućava razvoj sustava za nadzor koji bi funkcionirali u realnom vremenu [17]. Izvrstan su alat za modeliranje nelinearnih i stohastičkih procesa, kao i za prigušivanje šumova u signalima. U skladu s navedenim u 2. poglavlju, trošenje reznih alata je upravo izrazito nelinearan proces te se zbog stohastičke prirode procesa trošenja javljaju različiti poremećaji unutar signala. Estimirane vrijednosti parametra trošenja biti će filtrirane primjenom dinamičke neuronske mreže.


4.1. Dinamička neuronska mreža u ulozi filtra

Dinamičke neuronske mreže (DNM) jesu povratne neuronske mreže. Kod povratnih neuronskih mreža izlaz nekog neurona može, u općem slučaju, djelovati na sve druge neurone pa i na sebe samog povratno [4]. Ovo svojstvo očituje se u implementaciji povratne veze u samu strukturu mreže u obliku ugrađenog filtra što im omogućava znatno bolje učenje kada je riječ o estimaciji određenog parametra procesa. Iz navedenog može se zaključiti kako su DNM pogodan alat za identifikaciju dinamičkih sustava.

S obzirom na metodu učenja postoji više vrsta povratnih neuronskih mreža [4], ovdje će se razmatrati DNM s povratnim prostiranjem pogreške. Takva mreža sastoji se od najmanje tri sloja neurona: ulazni sloj, skriveni sloj i izlazni sloj. Po potrebi broj skrivenih slojeva može se povećati. Suštinski mreža ima strukturu unaprijedne mreže. Dinamika se u mrežu uvodi unutar skrivenog sloja pomoću dinamičkih neurona, odnosno dodavanjem dinamike ispred aktivacijske funkcije na način da aktivnost neurona ovisi o unutarnjim stanjima neurona [18]. U ovom radu dinamika će biti uvedena u obliku rekurzivnog, IIR i nerekurzivnog, FIR filtra.


4.2. Struktura mreže

Dinamičku neuronsku mrežu karakterizira dodavanje dinamike, odnosno ugradnja filtra unutar svakog od neurona skrivenog sloja. Najpoznatiji model filtra koji se ugrađuje u dinamičke neurone ispred aktivacijske funkcije je ARMA filtar tj. IIR filtar prikazan slikom 5. Ovaj filtar omogućuje djelovanje dinamičkog neurona na osnovu ulaznih signala ($u_j, u_j(n-1), u_j(n-2)$) i prethodno dobivenih vrijednosti izlazne veličine dinamičkog člana dinamičkog neurona ($\bar{y}(n-1), \bar{y}(n-2)$).




Slika 5. Dinamički neuron s ugrađenim IIR filtrom 2. reda

Na slici 6. prikazan je model dinamičkog neurona s ugrađenim FIR filtrom. Za razliku od rekurzivnog filtra, FIR filtar omogućuje djelovanje dinamičkog neurona na osnovu ulaznih signala ($u_j, u_j(n-1), u_j(n-2)$) ne uzimajući u obzir prethodne izlazne veličine.




Slika 6. Dinamički neuron s ugrađenim FIR filtrom 2. reda

U odnosu na dinamičku neuronsku mrežu izloženu u [4] u ovom radu biti će korištena modificirana verzija te mreže. Umjesto sigmoidalne bipolarne aktivacijske funkcije biti će korištena Gaussova aktivacijska funkcija (slika 7.). Korištenjem te AF, iz strukture i učenja mreže moguće je u potpunosti izostaviti BIAS neuron i njegove težine. S obzirom na to, centar Gaussove funkcije (c) kao i širina AF (σ) postaju parametri učenja.



Slika 7. Gaussova aktivacijska funkcija

Glavna prednost dinamičkog modela neurona s Gaussovom aktivacijskom funkcijom je da on smanjuje kompleksnost strukture mreže. Prednost adaptivne aktivacijske funkcije je ubrzanje algoritma učenja. Za istu grešku u učenju, neuronska mreža s adaptivnom Gaussovom aktivacijskom funkcijom treba gotovo dvostruko manje koraka učenja i postiže bolja generalizacijska svojstva od mreže sa sigmoidalnom aktivacijskom funkcijom [18].



Slika 8. Struktura DNM s Gaussovom aktivacijskom funkcijom [3]

Strukturu mreže čine tri sloja kao što je prikazano na slici 8. Ulazni sloj sadrži ulaze mreže koji su zapravo vanjski ulazni podaci. Drugi, skriveni sloj sastoji se od niza dinamičkih neurona. Ova dva sloja povezana su putem težinskih koeficijenata ulaznog sloja, v_{ji} . U skrivenom sloju nalazi se i već spomenuta Gaussova aktivacijska funkcija. Vezu između skrivenog i izlaznog sloja predstavljaju koeficijenti težina izlaznog sloja, w_{kj} . Izlazni sloj također sadrži aktivacijsku funkciju, međutim izabrana je linearna aktivacijska funkcija s pojačanjem $K_p = 1$. Izlazi mreže definirani su u izlaznom sloju.

4.3. Algoritam učenja mreže

Algoritam učenja ostvaren je unazadnim propagiranjem pogreške u smislu smanjenja gradijenta pogreške. Osim težina v i w , u procesu učenja mreža će učiti i koeficijente dinamičkih neurona a i b , ali i centar i širinu aktivacijske funkcije, c i σ . Promjena svih parametara učenja odvija se za svaki par ulazno-izlaznih vrijednosti zapisnika učenja. Podaci potrebni za trening mreže dobiveni su prethodnim snimanjem sustava čije ponašanje uči. Učenje se obavlja u dvije već videne faze, unaprijedna i povratna faza učenja [4].

4.3.1. Unaprijedna faza učenja

Proces učenja započinje unaprijednom fazom učenja u kojoj se iz datoteke za učenje uzimaju vrijednosti ulaza mreže Z pomoću kojih se računa vrijednost izlaza mreže O . Početne vrijednosti parametara učenja v , w , a , b , c i σ određene su generatorom slučajnih brojeva, dok su početne vrijednosti veličina koje se uzimaju iz prethodnih koraka postavljene kao nul-vrijednosti.

Sakriveni sloj:

Funkcija sume skrivenog sloja prikazana na slici 8. glasi:

$$net_{Hj} = \sum_{i=1}^{I-1} v_{ji} Z_i \quad , \quad j = 1, 2, \dots, J-1, \quad i = 1, 2, \dots, I-1, \quad (4.1)$$

gdje je I broj ulaznih neurona, a J broj neurona skrivenog sloja.

Ovisno o vrsti filtra razlikuje se izračun izlaza dinamičkih neurona. Izlazi dinamičkih članova $\bar{y}_j(n)$ u slučaju kada se koristi IIR filter računaju se prema jednadžbi 4.2, a za FIR filter prema jednadžbi 4.3:

$$\begin{aligned} \bar{y}_j(n) = & b_{0j}(n)net_{Hj}(n) + b_{1j}(n)net_{Hj}(n-1) + b_{2j}(n)net_{Hj}(n-2) - a_{1j}\bar{y}_j(n-1) \\ & - a_{2j}\bar{y}_j(n-2) , \end{aligned} \quad (4.2)$$

$$\bar{y}_j(n) = b_{0j}(n)net_{Hj}(n) + b_{1j}(n)net_{Hj}(n-1) + b_{2j}(n)net_{Hj}(n-2) . \quad (4.3)$$

Navedene jednadžbe vrijede za 2. red oba filtra. Za filter višeg reda potrebno je proširiti izraze (4.2) i (4.3).

Navedeni izlazi dinamičkih članova $\bar{y}_j(n)$ predstavljaju ulaze za odabranu aktivacijsku funkciju:

$$y_j(n) = e^{-\frac{1}{2}\left(\frac{\bar{y}_j(n)-c_j}{\sigma_j}\right)^2}, j = 1, 2, \dots, J. \quad (4.4)$$

Izlazni sloj:

Funkcija sume izlaznog sloja računa se prema slijedećoj jednadžbi:

$$net_{Ok} = \sum_{j=1}^J y_j(n) w_{kj}(n). \quad (4.5)$$

U izlaznom sloju primijenjena je linearna aktivacijska funkcija, stoga izraz za izlaze neuronske mreže glasi:

$$O_k(n) = net_{Ok}(n), k = 1, 2, \dots, K, \quad (4.6)$$

gdje K predstavlja broj izlaza mreže.

4.3.2. Povratna faza učenja

Povratna faza predstavlja drugu fazu učenja neuronske mreže. U njoj se, na osnovu razlike ostvarenih izlaza i željenih izlaza mreže izračunava pogreška učenja. Temeljem te pogreške vrši se korekcija vrijednosti težinskih koeficijenata veza među slojevima. Primjenom algoritma učenja s povratnim prostiranjem pogreške, promjena parametara odvija se od izlaznog prema ulaznom sloju mreže.

U svrhu minimiziranja pogreške učenja korištena je funkcija cilja:

$$E = \frac{1}{2} \sum_{n=1}^N (d_n - O_n)^2. \quad (4.7)$$

Promjena parametara učenja (težina, koeficijenata dinamičkih članova i parametara Gauss-ove funkcije) vrši se prema slijedećem algoritmu:

$$\vartheta(n+1) = \vartheta(n) - \eta \nabla E(\vartheta(n)) + \alpha \Delta \vartheta(n-1), \quad (4.8)$$

gdje je $\nabla E(\vartheta)$ gradijent pogreške, η mjera promjene, odnosno koeficijent brzine učenja i α koeficijent učenja ili tzv. „momentum“. Detaljan izvod ovog algoritma izložen je u [4].

Promjena parametara učenja izlaznog sloja:

Algoritam promjene težina izlaznog sloja glasi:

$$w_{kj}(n+1) = w_{kj}(n) + \eta \delta_{Ok} y_j + \alpha \Delta w_{kj}(n-1), \quad (4.9)$$

gdje je:

$$\nabla E(n) = \frac{\partial E(n)}{\partial w_{kj}} = \frac{\partial E(n)}{\partial O_k} * \frac{\partial O_k}{\partial net_{Ok}} * \frac{\partial net_{Ok}}{\partial w_{kj}}, \quad (4.10)$$

$$\frac{\partial E(n)}{\partial O_k} = -(d_k - O_k) = -\delta_{Ok}, \quad (4.11)$$

$$\frac{\partial O_k}{\partial net_{Ok}} = 1, \quad (4.12)$$

$$\frac{\partial net_{Ok}}{\partial w_{kj}} = y_j. \quad (4.13)$$

Promjena parametara Gauss-ove funkcije također se odvija u izlaznom sloju. Promjena parametra c odvija se prema slijedećem izrazu:

$$c_j(n+1) = c_j(n) + \frac{y_j}{\sigma_j^2} \eta (\bar{y}_j - c_j) (\sum_{k=1}^K \delta_{Ok} w_{kj}) + \alpha \Delta c_j(n-1), \quad (4.14)$$

gdje je:

$$\nabla E(n) = \frac{\partial E(n)}{\partial c_j} = \frac{\partial E(n)}{\partial y_j} * \frac{\partial y_j}{\partial c_j}, \quad (4.15)$$

$$\frac{\partial E(n)}{\partial y_j} = -\sum_{k=1}^K \delta_{Ok} * w_{kj}, \quad (4.16)$$

$$\frac{\partial y_j}{\partial c_j} = \frac{y_j}{\sigma_j^2} * (\bar{y}_j - c_j). \quad (4.17)$$

Promjena parametra σ odvija se na isti način:

$$\sigma_j(n+1) = \sigma_j(n) + \frac{y_j}{\sigma_j^3} \eta (\bar{y}_j - c_j)^2 (\sum_{k=1}^K \delta_{Ok} w_{kj}) + \alpha \Delta \sigma_j(n-1), \quad (4.18)$$

gdje je:

$$\nabla E(n) = \frac{\partial E(n)}{\partial \sigma_j} = \frac{\partial E(n)}{\partial y_j} * \frac{\partial y_j}{\partial \sigma_j}, \quad (4.19)$$

$$\frac{\partial E(n)}{\partial y_j} = -\sum_{k=1}^K \delta_{Ok} * w_{kj}, \quad (4.20)$$

$$\frac{\partial y_j}{\partial \sigma_j} = \frac{y_j}{\sigma_j^3} * (\bar{y}_j - c_j)^2. \quad (4.21)$$

Promjena parametara učenja skrivenog sloja:

Nakon promjene svih parametara izlaznog sloja slijedi promjena koeficijenata dinamičkih članova skrivenog sloja. Budući da su u ovom radu korištene dvije vrste filtra, biti će prikazane promjene parametara dinamičkog neurona u oba slučaja. Da bi se pojednostavio prikaz potrebnih derivacija algoritma učenja, definiran je linearni operator vremenskog pomaka, koji u slučaju korištenja IIR filtra 2. reda glasi:

$$[\bar{y}(n)] = \frac{B(z)}{A(z)}[net(n)], \quad z^{-i}[net(n)] = net(n - i), \quad (4.22)$$

$$A(z)[\bar{y}(n)] = \bar{y}(n) + a_1\bar{y}(n - 1) + a_2\bar{y}(n - 2), \quad (4.23)$$

$$B(z)[net(n)] = b_0net(n) + b_1net(n - 1) + b_2net(n - 2). \quad (4.24)$$

Za filter višeg reda (4. i 6. red) potrebno je proširiti izraze (4.23) i (4.24).

Za FIR filter linearni operator vremenskog pomaka ima izmijenjen oblik budući da ovaj filter ne uzima u obzir izlaze mreže iz prethodnih koraka već samo ulaze. Izraz koji to pokazuje je slijedeći:

$$[\bar{y}(n)] = B(z)[net(n)], \quad z^{-i}[net(n)] = net(n - i), \quad (4.25)$$

$$B(z)[net(n)] = b_0net(n) + b_1net(n - 1) + b_2net(n - 2). \quad (4.26)$$

Jednadžba (4.26) napisana je za filter 2. reda te ju je potrebno proširiti prilikom korištenja filtra višeg reda.

Promjena parametara učenja b_{0j} , b_{1j} i b_{2j} odvija se prema izrazu (4.8). Izrazi će biti izvedeni za filtre 2. reda te ih je kao i kod promjene parametara izlaznog sloja potrebno proširiti prilikom korištenja filtra višeg reda. Uvrštavanjem parametra b_{ij} u izraz (4.8) dobiva se opći oblik promjene parametara b_{ij} koji glasi:

$$b_{ij}(n + 1) = b_{ij}(n) - \frac{y_j}{\sigma_j^2} \eta (\bar{y}_j - c_j) D_{b_{ij}}(n) \left(\sum_{k=1}^K \delta_{Ok} w_{kj} \right) + \alpha \Delta b_{ij}(n - 1),$$

$$i=0,1,2, \quad (4.27)$$

gdje je:

$$\nabla E = \frac{\partial E(n)}{\partial b_{ij}} = \frac{\partial E(n)}{\partial y_j} * \frac{\partial y_j}{\partial \bar{y}_j} * \frac{\partial \bar{y}_j}{\partial b_{ij}}, \quad (4.28)$$

$$\frac{\partial E(n)}{\partial y_j} = - \sum_{k=1}^K \delta_{Ok} * w_{kj}, \quad (4.29)$$

$$\frac{\partial y_j}{\partial \bar{y}_j} = -\frac{y_j}{\sigma_j^2} * (\bar{y}_j - c_j), \quad (4.30)$$

$$\frac{\partial \bar{y}_j}{\partial b_{ij}} = D_{bi_j}(n). \quad (4.31)$$

Linearni operator vremenskog pomaka za IIR filter dan je izrazom:

$$\left[D_{bi_j}(n) \right] = \frac{z^{-i}}{A(z)} [net(n)], \quad i = 0,1,2. \quad (4.32)$$

S druge strane, za FIR filter koristi se nešto izmijenjen izraz:

$$\left[D_{bi_j}(n) \right] = Z^{-i} [net(n)], \quad i = 0,1,2. \quad (4.33)$$

Promjena parametara učenja a_{1j} i a_{2j} također se odvija prema izrazu (4.8) i isključivo za IIR filter. Za računanje gradijenta pogreške vrijede izrazi (4.29) i (4.30). Razlika se pojavljuje u zadnjem članu parcijalnih derivacija što će biti pokazano u nastavku. Opći oblik algoritma promjene parametra a_{ij} glasi:

$$a_{ij}(n+1) = a_{ij}(n) - \frac{y_j}{\sigma_j^2} \eta (\bar{y}_j - c_j) D_{ai_j}(n) \left(\sum_{k=1}^K \delta_{Ok} w_{kj} \right) + \alpha \Delta a_{ij}(n-1),$$

$$i = 1,2, \quad (4.34)$$

gdje je :

$$\nabla E = \frac{\partial E(n)}{\partial a_{ij}} = \frac{\partial E(n)}{\partial y_j} * \frac{\partial y_j}{\partial \bar{y}_j} * \frac{\partial \bar{y}_j}{\partial a_{ij}}, \quad (4.35)$$

$$\frac{\partial \bar{y}_j}{\partial a_{ij}} = D_{ai_j}(n), \quad (4.36)$$

$$\left[D_{ai_j}(n) \right] = \frac{-z^{-i}}{A(z)} [\bar{y}(n)], \quad i = 1,2. \quad (4.37)$$

Nakon što su izvršene promjene parametara dinamičkog neurona slijedi promjena koeficijenata težina skrivenog sloja v_{ij} . Opći oblik algoritma promjene parametra učenja v_{ij} dobiven uvrštavanjem u izraz (4.8) i glasi:

$$v_{ij}(n+1) = v_{ij}(n) - \frac{y_j}{\sigma_j^2} \eta (\bar{y}_j - c_j) D_{vi_j}(n) \left(\sum_{k=1}^K \delta_{Ok} w_{kj} \right) + \alpha \Delta v_{ij}(n-1), \quad (4.38)$$

gdje je:

$$\nabla E = \frac{\partial E(n)}{\partial v_{ij}} = \frac{\partial E(n)}{\partial y_j} * \frac{\partial y_j}{\partial \bar{y}_j} * \frac{\partial \bar{y}_j}{\partial v_{ij}}, \quad (4.39)$$

$$\frac{\partial \bar{y}_j}{\partial v_{ij}} = D_{v_{ij}}(n). \quad (4.40)$$

Za preostale parcijalne derivacije u gradijentu pogreške vrijede izrazi (4.29) i (4.30). Linearni operator za IIR filter glasi:

$$\left[D_{v_{ij}}(n) \right] = \frac{B(z)}{A(z)} [Z_i(n)]. \quad (4.41)$$

Operator vremenskog pomaka za FIR filter dan je izrazom:

$$\left[D_{v_{ij}}(n) \right] = B(z) [Z_i(n)]. \quad (4.42)$$

4.3.3. Ocjena uspješnosti algoritma

Kako bi se procijenila točnost (uspješnost) algoritma učenja, definirana je mjera točnosti. Postoji više različitih mjera točnosti. One najčešće izložene su u [4], a u ovom radu korišten je normalizirani korijen srednje kvadratne pogreške, *NRMS* koji glasi:

$$NRMS = \frac{RMS}{\sigma_{d_n}} = \frac{\sqrt{\frac{\sum_{n=1}^N (d_n - o_n)^2}{N}}}{\sigma_{d_n}}, \quad (4.43)$$

gdje je:

$$\sigma_{d_n} = \sqrt{\frac{1}{N} \sum_{n=1}^N (d_n - \bar{d})^2}, \quad (4.44)$$

$$\bar{d} = \frac{1}{N} \sum_{n=1}^N d_n. \quad (4.45)$$

Prednost odabrane mjere je njena bezdimenzionalnost koja osigurava neovisnost mjere o dimenzijama učenih veličina i koja omogućuje usporedbu izvedenih algoritama učenja s drugim algoritmima, neovisno o korištenoj sklopovskoj ili programskoj podršci [4].

5. ANALIZA REZULTATA

Dinamičke neuronske mreže trenirane su pomoću eksperimentalno prikupljenih podataka iz procesa tokarenja. Kada mreža sa zadovoljavajućom uspješnosti nauči skup za učenje, njezine ulazne vrijednosti zamjenjuju se novim skupom podataka iz istog procesa i mreža se tada koristi kao filter za pogrešku estimacije u sustavu nadzora obradnog stroja prema istrošenosti reznog alata. Parametar koji je estimiran, odnosno kasnije filtriran je širina trošenja stražnje površine alata, VB. Svaka mreža testirana je sa 7 testova. Svi podaci za učenje i testovi generirani su korištenjem dubine rezanja $a_p = 2,5$ mm i posmaka alata $f = 0,35$ mm/okr kao što je navedeno u poglavlju 2. gdje su i prikazane simulirane krivulje trošenja.

5.1. Faza učenja

U fazi učenja neuronska mreža uči povezanost između ulaza mreže i željenih izlaza. U tom procesu mreža mijenja parametre kako bi u konačnici razlika između dobivenih i željenih izlaza bila što manja, odnosno algoritam učenja uspješniji.

Odabrana struktura mreže za sve vrste filtera je 5-5-1 zato što se njome postižu ujednačeni i zadovoljavajući rezultati, kako je iznijeto u [3]. Mreže su učene s faktorom učenja $\eta = 0,01$ i momentumom $\alpha = 0,08$. Učenje je provedeno u 10 000 iteracija.

Kao što je već spomenuto, radi simulacije realnih uvjeta ulazni podaci u mrežu zašumljeni su estimacijskim pogreškama u iznosu od 0,05 mm i 0,1 mm. Pogreška od 0,05 mm realno je očekivana pogreška u praksi prilikom estimacije, dok pogreška od 0,1 mm predstavlja izrazito veliku grešku estimatora i čini sustav nadzora nepouzdanim. Svaka mreža učena je i testirana zasebno za podatke vezane uz pogrešku estimacije 0,05 i 0,1 mm.

Rezultati učenja i generalizacijska svojstva mreže iskazani su pomoću NRMS faktora.


Tablica 1. Rezultati učenja mreža za podatke s estimacijskom pogreškom 0,05 mm

Vrsta filtra	Red filtra	NRMS učenja	Minimalni NRMS	Korak učenja za minimalni NRMS
IIR	2	0.1376	0,1306	866
	4	0.1148	0,1137	4345
	6	1,8133	1,8133	10 000
FIR	2	0,1221	0,1221	10 000
	4	0,1046	0,1046	10 000
	6	0,1160	0,1160	10 000

Tablica 2. Rezultati učenja mreža za podatke s estimacijskom pogreškom 0,1 mm


Vrsta filtra	Red filtra	NRMS učenja	Minimalni NRMS	Korak učenja za minimalni NRMS
IIR	2	0.2954	0,2455	96
	4	0.2618	0,2618	10 000
	6	0,09643	1,0029	10 000
FIR	2	0.1928	0,1928	10 000
	4	0,1989	0,1989	10 000
	6	0,2459	0,2459	10 000

Prema rezultatima prikazanim u tablicama 1. i 2. vidljivo je da se kod IIR filtra 2. i 4. reda za podatke s estimacijskom pogreškom 0,05 mm javlja pretreniranost mreže, kao i za IIR filter 2. reda za estimacijsku pogrešku 0,1 mm. To znači da učenjem u većem broju koraka od koraka u kojem se postiže minimalni NRMS dolazi do pretreniranosti mreže. Drugim riječima, mreža toliko dobro nauči podatke iz skupa za učenje da izgubi generalizacijska svojstva nad podacima za testiranje. Budući da su najbolji parametri mreže dobiveni u koracima kada je NRMS minimalan, oni će biti korišteni u fazi testiranja. Slikom 9. prikazan je primjer pretreniranosti mreže za IIR filter 2. reda.




Slika 9. Krivulja NRMS faktora za IIR filtar 2. reda (za estimacijsku pogrešku 0,1 mm)

Odzivi najuspješnijih mreža na datoteku učenja prikazani su slikama 10. i 11.



Slika 10. Odziv mreže na datoteku učenja (za estimacijsku pogrešku 0,05 mm)



Slika 11. Odziv mreže na datoteku učenja (za estimacijsku pogrešku 0,1 mm)

5.2. Faza testiranja

Testovi su generirani za slijedeće brzine rezanja $v_c = 125, 155, 185, 205, 225, 245, 265$ m/min. Parametri testova prikazani su u tablici 3.

Tablica 3. Parametri testova

Test	Brzina rezanja, v_c (m/min)	Vrsta poremećaja	Period djelovanja poremećaja, t (min)
Test 1	125	bez dodatnih poremećaja	-
Test 2	155	impulsni poremećaj, $\delta_i^I = 0,1$	10
Test 3	185	impulsni poremećaj, $\delta_i^I = 0,5$	15
Test 4	205	varijabilni poremećaj, $\delta_i^V = 0,3$	7 – 15
Test 5	225	varijabilni poremećaj, $\delta_i^V = 0,6$	7 – 15
Test 6	245	varijabilni poremećaj, $\delta_i^V = -0,3$	7 – 15
Test 7	265	varijabilni poremećaj, $\delta_i^V = -0,6$	7 – 15

Impulsni poremećaji vezani su uz naglo trošenje stražnje površine alata VB. Pozitivan varijabilni poremećaj vezan je za obradu tvrđe faze u materijalu u odnosu na ostatak obratka, čime se u tom periodu ubrzava trošenje alata. Suprotno tome, negativan varijabilni poremećaj vezan je za obradu mekše faze u materijalu u odnosu na ostali dio materijala obratka, čime se u tom periodu usporava trošenje alata.

Tablica 4. Rezultati učenja i testiranja IIR filtra za grešku estimacije 0,05 mm

Vrsta filtra	IIR		
	2	4	6
NRMS učenja	0,1306	0,1137	1,8133
NRMS test 1	0,17609	0,18007	0,16468
NRMS test 2	0,14514	0,16505	0,13544
NRMS test 3	0,20651	0,20366	0,21324
NRMS test 4	0,11671	0,16252	0,12875
NRMS test 5	0,16002	0,18622	0,13664
NRMS test 6	0,16871	0,17496	0,17283
NRMS test 7	0,25347	0,25263	0,27972
NRMS prosjek testova:	0,17524	0,18931	0,17590

Tablica 5. Rezultati učenja i testiranja FIR filtra za grešku estimacije 0,05 mm

Vrsta filtra	FIR		
	2	4	6
NRMS učenja	0,1221	0,1046	0,1160
NRMS test 1	0,16846	0,15172	0,19245
NRMS test 2	0,14363	0,13177	0,17119
NRMS test 3	0,19252	0,16541	0,22792
NRMS test 4	0,12324	0,11743	0,14669
NRMS test 5	0,15396	0,14006	0,15951
NRMS test 6	0,18031	0,16395	0,15208
NRMS test 7	0,26965	0,22919	0,20201
NRMS prosjek testova:	0,17597	0,15707	0,17884

U tablicama 4. i 5. prikazani su rezultati učenja i testiranja mreža za podatke iz procesa tokarenja zašumljene s estimacijskom greškom 0,05 mm. U fazi učenja mreže najbolje rezultate daju IIR i FIR 4. reda. Usporedbom svih redova IIR filtara u fazi testiranja, filtar 2. reda ostvaruje najbolje rezultate. S druge strane, kod FIR filtra struktura s 4. redom ima najmanji NRMS testiranja što je ujedno i najuspješnija struktura filtra za ovaj skup podataka. Iz

prikazanih rezultata može se uočiti kako sve strukture filtera daju najlošije rezultate za test 7 kada se u procesu obrade javlja veliki negativni varijabilni poremećaj.

Tablica 6. Rezultati učenja i testiranja IIR filtra za grešku estimacije 0,1 mm

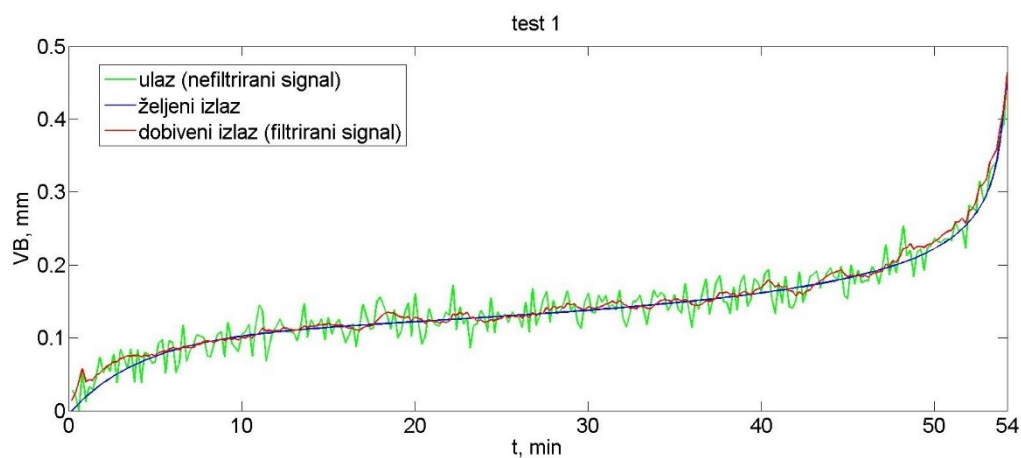
Vrsta filtra	IIR		
	2	4	6
NRMS učenja	0,2455	0,2618	1,0029
NRMS test 1	0,38729	0,61851	0,51559
NRMS test 2	0,36254	0,57239	0,48605
NRMS test 3	0,44448	0,53078	0,45811
NRMS test 4	0,30051	0,40011	0,32161
NRMS test 5	0,29062	0,37518	0,30907
NRMS test 6	0,28737	0,32381	0,30825
NRMS test 7	0,34956	0,41277	0,38632
NRMS prosjek testova:	0,34605	0,46193	0,39786

Tablica 7. Rezultati učenja i testiranja FIR filtra za grešku estimacije 0,1 mm


Vrsta filtra	FIR		
	2	4	6
NRMS učenja	0,1928	0,1989	0,2459
NRMS test 1	0,40394	0,42238	0,49131
NRMS test 2	0,39501	0,38951	0,48677
NRMS test 3	0,34383	0,36654	0,49473
NRMS test 4	0,29263	0,28135	0,36302
NRMS test 5	0,26113	0,24522	0,32469
NRMS test 6	0,29051	0,26837	0,29873
NRMS test 7	0,41151	0,33708	0,39501
NRMS prosjek testova:	0,34265	0,33006	0,40775

Tablice 6. i 7. prikazuju rezultate učenja i testiranja mreža na temelju podataka zašumljenih estimacijskom pogreškom u iznosu od 0,1 mm. U ovom slučaju rezultati učenja FIR filtra značajno su bolji od IIR filtra. Rezultati testiranja ne pokazuju toliku razliku između dva filtra, ali bolje rezultate ostvaruje FIR filtar što je u skladu s rezultatima učenja. FIR filtar 4. reda pokazao se kao najuspješniji i u ovom slučaju. Također treba primijetiti kako IIR filtar 4. reda daje značajno lošije rezultate od istog filtra 2. i 6. reda.


Iz prethodno prikazanih rezultata vidljivo je da FIR filtar 4. reda za podatke s estimacijskom pogreškom 0,05 mm daje najbolje rezultate prilikom testiranja. Rezultati tih testova prikazani su na slikama 12, 13, 14, 15, 16, 17 i 18.



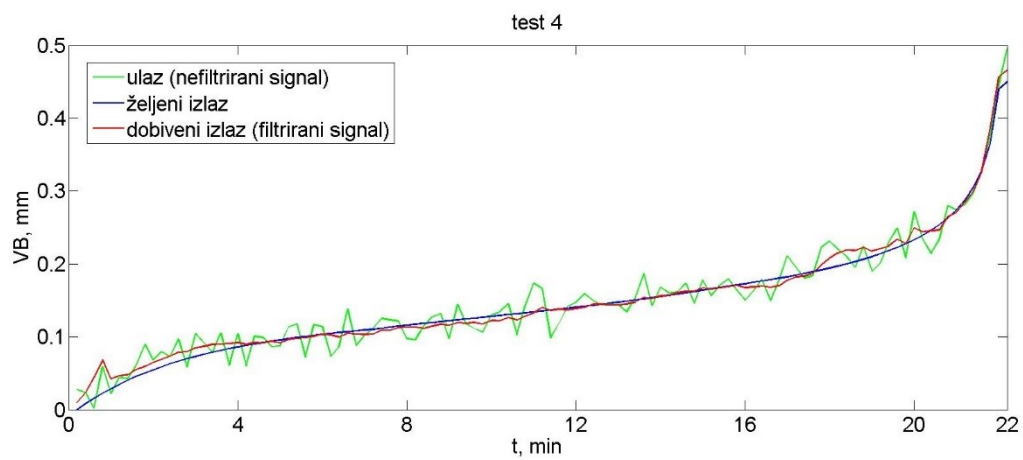
Slika 12. Odziv mreže na test 1




Slika 13. Odziv mreže na test 2



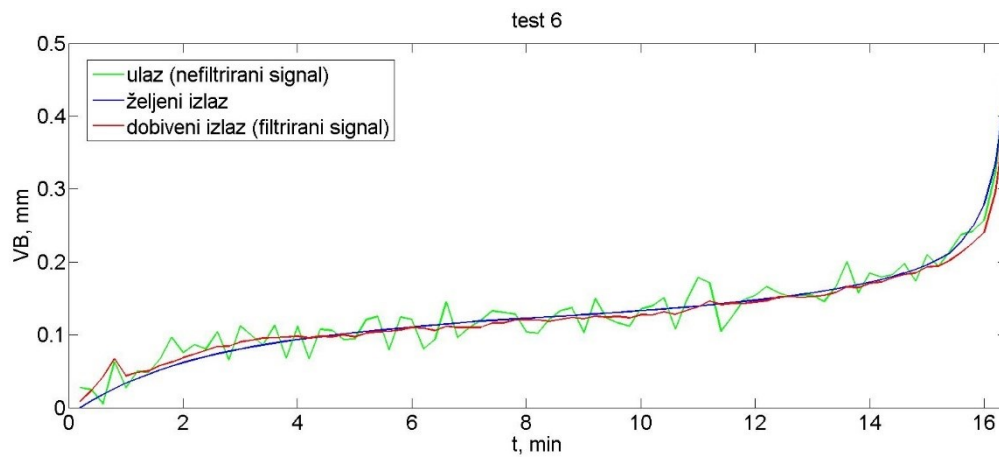
Slika 14. Odziv mreže na test 3



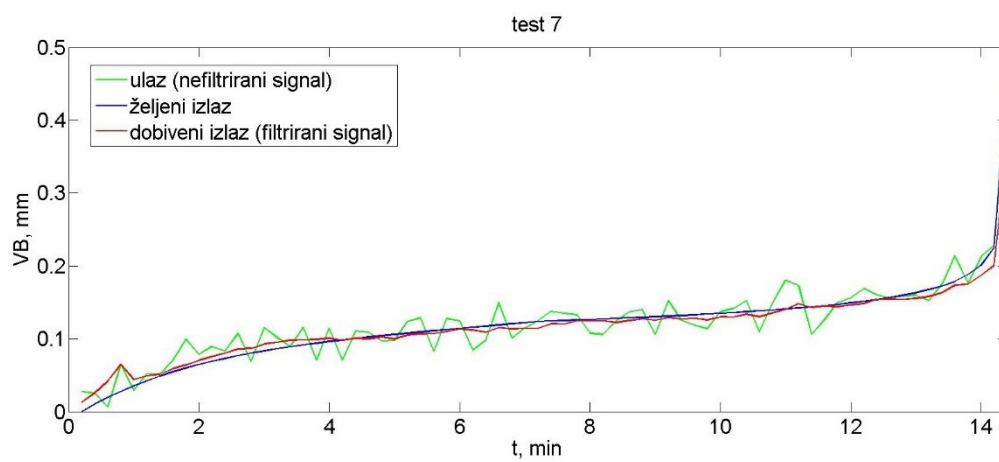
Slika 15. Odziv mreže na test 4



Slika 16. Odziv mreže na test 5



Slika 17. Odziv mreže na test 6



Slika 18. Odziv mreže na test 7

6. ZAKLJUČAK

Adaptivno vođenje alatnog stroja predmet je brojnih istraživanja i predstavlja budućnost inteligentne proizvodnje i industrije općenito. Razlog tomu je povećana sigurnost i produktivnost procesa obrade, ali i povećanje kvalitete obrađene površine. Predmet istraživanja ovog rada predstavljala je analiza i usporedba efikasnosti dvaju filtara, rekurzivnog (IIR) i nerekurzivnog (FIR). Cilj ovog ispitivanja bio je analizom dobivenih rezultata pronaći najadekvatnije rješenje kako bi se smanjila pogreška estimatora stupnja istrošenosti stražnje površine reznog alata. Smanjenjem estimacijske pogreške smanjuje se njezin utjecaj na regulacijski krug, odnosno na izvršni član obradnog stroja.

Analiza je provedena primjenom matematičkog modela trošenja koji je postavljen na temelju eksperimentalno prikupljenih podataka iz procesa obrade tokarenjem. Kako bi matematički model što vjernije prikazao proces trošenja, samom modelu dodano je nekoliko vrsta poremećaja, kao i slučajno generirane pogreške estimatora.

Algoritam za obradu podataka i modeliranja filtara predstavljala je dinamička neuronska mreža. Korištena je modificirana dinamička neuronska mreža, a modifikacija se očituje u primjeni Gauss-ove aktivacijske funkcije.

Ulazne signale u mrežu predstavljale su estimirane vrijednosti parametra trošenja koji je promatran (stražnja površina alata). Proces učenja proveden je za svaku vrstu i red filtra te su temeljem uspješnosti učenja definirani parametri mreže kao i broj koraka učenja. Korištena su dva skupa podataka za učenje za različite iznose estimacijskih pogrešaka. Mreže su zatim testirane. Svaki od testova sadržavao je različitu vrstu poremećaja, različitog intenziteta i trajanja.

Temeljem postignutih rezultata može se zaključiti da su najbolji rezultati ostvareni korištenjem FIR filtra 4. reda. Struktura FIR filtra jednostavnija od strukture koju ima IIR filter, stoga se može zaključiti da bi njegova primjena manje opterećivala sustav prilikom obrade podataka što se može očitovati u bržoj obradi signala prilikom adaptivnog vođenja alatnog stroja.

Iz prikazanih grafova vidljivo je da filter ne može u potpunosti ukloniti estimacijsku pogrešku i poremećaje iz signala međutim istraživanja na ovom području su pokazala kako su takvi odzivi zadovoljavajući kada se filtri implementiraju u regulacijski krug u svrhu adaptivnog vođenja.

Eventualno poboljšanje rezultata na ovom području moglo bi se postići promjenom aktivacijske funkcije neuronske mreže, ali i promjenom vrste filtra kao i njegovog reda. Također, primjenom neke druge vrste algoritma za realizaciju filtra mogli se potencijalno postići bolji rezultati.

LITERATURA

- [1] Das S, Chattopadhyaya AB, Murthy ASR. Force Parameters for On-line Tool Wear Estimation: A Neural Network Approach. *Neural Networks*. 1996;9(9):1639-1645
- [2] Bature A, Adamu SS. Design of Digital Recursive Filter Using Artificial Neural Network. *Proceedings of the International MultiConference of Engineers and Computer Scientists: IMECS 2012, 14th to 16th March 2012, Hong Kong*.
- [3] Brezak D. Razvoj hibridnog estimatora trošenja alata i metoda vođenja alatnog stroja [doktorski rad]. Zagreb: Fakultet strojarstva i brodogradnje; 2007.
- [4] Novaković B, Majetić D, Široki M. Umjetne neuronske mreže. Zagreb: Fakultet strojarstva i brodogradnje; 1998.
- [5] Škorić S. Materijali za predavanja iz kolegija Obrada odvajanjem. Zagreb: Fakultet strojarstva i brodogradnje; 2015.
- [6] Staroveški T. Modeliranje trošenja medicinskog svrdla [doktorski rad]. Zagreb: Fakultet strojarstva i brodogradnje; 2013.
- [7] Brezak D, Majetić D, Udiljak T, Kasać J. Flank Wear Regulation using Artificial Neural Networks. *Journal of Mechanical Science and Technology*. 2010;24(5):1041
- [8] Koren Y, Lenz E. Mathematical Model of the Flank–Wear while turning Steel with Carbide Tools. *CIRP Proceedings of Manufacturing Systems*. 1972;1(2)
- [9] Smith S. *The Scientist and Engineer's Guide to Digital Signal Processing*. 2nd ed. San Diego: California Technical Publishing; 1999.
- [10] Sučić V. Materijali za predavanja iz kolegija Signali i sustavi. Rijeka: Tehnički fakultet.
- [11] Mitra S. *Digital Signal Processing: A Computer - Based Approach*. 3rd ed. Santa Barbara: McGraw – Hill; 2005.
- [12] Kuo SM, Lee BH, Tian W. *Real-Time Digital Signal Processing: Implementations and Applications*. 2nd ed. Chichester: John Wiley & Sons Ltd; 2006.
- [13] Brezak D, Staroveški T. Materijali za predavanja iz kolegija Regulacija obradnih strojeva. Zagreb: Fakultet strojarstva i brodogradnje; 2019.
- [14] Elliott DF. *Handbook of Digital Signal Processing: Engineering Applications*. San Diego: Academic Press, Inc.; 1987.
- [15] Salimi A, Abbasgholizadeh S, Taghizadeh S, Safarian A. Using of Artificial Neural Networks to Predict Drill Wear in Machining Processes. *Australian Journal of Basic and Applied Sciences*. 2011;5(12): 2752-2760.

- [16] Cho HS, Leu MC. Artificial Neural Networks in Manufacturing Processes: Monitoring and Control. 9th IFAC Symposium on Information Control in Manufacturing: INCOM 1998, 24th to 26th June 1998, Nancy, France.
- [17] Murat Z. Multisenzorski sustav za indirektni nadzor istrošenosti medicinskih svrdla [Diplomski rad]. Zagreb: Fakultet strojarstva i brodogradnje; 2016.
- [18] Majetić D, Brezak D, Novaković B, Kasać J. Dynamic neural network with adaptive Gauss neuron activation function. DAAAM Scientific Book. 2004.