SVEUČILIŠTE U RIJECI **TEHNIČKI FAKULTET**

PREDVIĐANJE PARAMETARA RADA BRODSKOG DIZELSKOG MOTORA PRIMJENOM NEURONSKIH MREŽA

Doktorska disertacija

Ozren Bukovac

Rijeka, 2012.

SVEUČILIŠTE U RIJECI **TEHNIČKI FAKULTET**

PREDVIĐANJE PARAMETARA RADA BRODSKOG DIZELSKOG MOTORA PRIMJENOM NEURONSKIH MREŽA

Doktorska disertacija

Ozren Bukovac

Mentor: Red. prof. dr. sc. Vladimir Medica, dipl. ing. Komentor: Izv. prof. dr. sc. Radovan Antonić, dipl. ing.

Rijeka, 2012.

Sveučilište u Rijeci **TEHNIČKI FAKULTET** -Fakultetsko vijeće-Klasa: 602-04/08-02/20 Ur. br.: 2170-57-43-08-34 Rijeka, 29. rujna 2008.

Fakultetsko vijeće Tehničkog fakulteta Sveučilišta u Rijeci, na svojoj 20. sjednici u akad. god. 2007./08./09./10., održanoj 26. rujna 2008., donijelo je sljedeću

ODLUKU

Sukladno izvješću Stručnog povjerenstva, u sastavu: red. prof. dr. sc. Vladimir Medica, izv. prof. dr. sc. Tomislav Mrakovčić i izv. prof. dr. sc. Radovan Antonić (Pomorski fakultet Sveučilišta u Splitu), te pozitivne ocjene prijave i obrane teme doktorskog rada, utvrđuje se da pristupnik *Ozren Bukovac, dipl. ing.* ispunjava Zakonom propisane uvjete za prijavu i izradu teme doktorske disertacije naslovljene:

"Predviđanje parametara rada brodskog dizelskog motora primjenom neuronskih mreža"

Mentorom se imenuje red. prof. dr. sc. Vladimira Medicu, a komentorom izv. prof. dr. sc. Radovana Antonića (Pomorski fakultet Sveučilišta u Splitu).

ekan rof dr. se Tonči Mikac, mag. ing. mech.

Dostaviti:

- 1. Ozren Bukovac, dipl. ing.
- 2. Mentor, red. prof. dr. sc. Vladimir Medica
- 3. Komentor, izv. prof. dr. sc. Radovan Antonić
- 4. Služba studentske evidencije, ovdje
- 5. Pismohrana FV

Sažetak

Dvotaktni sporohodni brodski dizelski motori s prednabijanjem imaju prednosti zbog svog visokog stupnja djelovanja i pouzdanosti. Suvremeni sporohodni brodski dizelski motori imaju veliku fleksibilnost u radu obzirom na varijabilne strategije ubrizgavanja goriva i upravljanja ispušnog ventila. Uvjeti proizvođača motora, nužni za pouzdanost rada i priznavanje garantnih uvjeta, koji definiraju strategiju brzine povećanja opterećenja i vođenje rada motora, ugrađeni su u sustav regulacije i zaštite rada motora.

Modeli za numeričke simulacije rada motora u stanju su vrlo pouzdano prognozirati karakteristike i ponašanje motora u različitim pogonskim uvjetima. One omogućuju bolji uvid u različite aspekte rada motora, te dobivanje dodatnih informacija iz ograničeno dostupnih eksperimentalnih podataka.

Ovim istraživanjem razvijen je model, baziran na neuronskim mrežama, koji omogućuje predviđanje parametara rada brodskog dizelskog motora. U radu se istražuje efikasno predviđanje radnih parametara u svrhu optimalnog upravljanja, kao i prepoznavanja kvarova i poteškoća rada pojedinih komponenti iz dostupnih izmjerenih podataka na realnom motoru. Istražena je i mogućnost da se izlazni rezultati naučenih neuronskih mreža koriste kao ulazni podaci za optimizaciju traženih radnih uvjeta.

Rezultati numeričkih simulacija za uvjete rada brodskog dizelskog motora primjenjeni su za odabir vrste i strukture neuronske mreže koja je korištena u ovom radu, njeno učenje i validaciju. Tako odabrana neuronska mreža spremna je za prihvat budućih eksperimentalnih podataka i njihovu obradu.

U radu su pokazani primjeri primjene opisane neuronske mreže za optimizaciju mogućih podešenja suvremenih brodskih "inteligentnih" dizelskih motora, s ciljem dovođenja traženog toplinskog toka ispušnih plinova radne uvjete za potrebe utilizacije, uz minimalnu specifičnu potrošnju goriva na motoru.

Prikazana neuronska mreža namjenjena je za implementaciju u suvremene inteligentne sustave vođenja glavnog brodskog dizelskog motora.

Abstract

Two-stroke low speed marine diesel engines with turbocharging have advantages because of its high efficiency and reliability. Modern low speed marine diesel engines have great exibility in operation, due to variable fuel injection strategies and governance of exhaust valve. Terms of engine manufacturers, necessary for operation reliability and accepting guarantee conditions, which define the strategy of loading speed and engine operation guidance, were built into the regulation and protection system of engine.

Numerical simulation models of engine operating parameters are capable for very reliably predictions of the characteristics and engine behavior in different operating conditions. They provide better insight into various aspects of engine operating parameters, and obtaining additional information from limited available experimental data.

This study developed a model, based on neural networks, which allows prediction of marine diesel engine working parameters. Presented paper investigates efficient prediction of engine operating parameters for optimal control as well as identification of failures and individual component operating difficulties from the available measured data on a real engine. It is also explored the possibility that the output of a learned neural networks are used as input data for optimizing the required operating conditions.

Numerical simulation results of marine diesel engine operating parameters have been applied in selection of neural network type and structure which was used in this paper, for her learning and validation. Selected neural network is ready for the reception of future experimental data and their processing.

Paper describes an example of neural network application for possible settings optimization on ship "intelligent" diesel engines, with the aim of bringing required exhaust gases heat flow in working conditions for utilization, with the minimum engine specific fuel consumption.

The presented neural network is designed for implementation in contemporary intelligent systems of the main marine diesel engine.

Predgovor

Izrada ovog rada provedena je pod mentorstvom red. prof. dr. sc. Vladimira Medice i izv. prof. dr. sc. Radovana Antonića, pa im ovom prilikom zahvaljujem za pomoć i podršku koju su mi pružili pri izradi i dovršenju rada. Zahvaljujem se izv. prof. dr. sc. Tomislavu Mrakovčiću, kao i doc. dr. sc Tomislavu Senčiću za niz konstruktivnih primjedbi, korisne savjete i podršku tijekom izrade rada.

Isto tako, zahvaljujem se svima ostalima, a osobito kolegi Vedranu Mrzljaku, koji je tu bio kad su vremena bila teška i kad je trebalo preuzeti veliki dio obaveza, osobito u nastavi.

Autor

Sadržaj

1	Uvo	Uvod 1							
	1.1	1 Sporohodni brodski dizelski motori							
	1.2	Cilj istraživanja	2						
	1.3	Obrazloženje radne hipoteze	3						
	1.4	Struktura rada	3						
2	Pret	thodna istraživanja	5						
3	Mat	zematički model dizelskog motora	7						
	3.1	Jednadžbe očuvanja mase i energije	8						
	3.2	Cilindar motora	9						
		3.2.1 Prijelaz topline u cilindru	1						
		3.2.2 Propuštanje radnog medija	2						
		3.2.3 Kompresija i ekspanzija	2						
		3.2.4 Izgaranje	2						
		3.2.5 Zakašnjenje paljenja	3						
		3.2.6 Potpunost izgaranja $\ldots \ldots 1$	4						
		3.2.7 Izmjena radnog medija kod četverotaktnog motora 1	6						
		3.2.8 Izmjena radnog medija kod dvotaktnog motora 1	7						
		3.2.8.1 Način ispiranja cilindra velikih brodskih dvotaktnih motora 1	8						
		3.2.8.2 Modeli izmjene radnog medija	8						
		3.2.8.3 Model potpunog miješanja	9						
	3.3	Usisni kolektor	0						
		3.3.1 Prijelaz topline u usisnom kolektoru	1						
		3.3.2 Hladnjak zraka	2						
	3.4	Ispušni kolektor	3						
		3.4.1 Prijelaz topline u ispušnom kolektoru	4						
	3.5	Turbopuhalo	4						
		3.5.1 Turbina na ispušne plinove	5						
		3.5.2 Puhalo	27						
		3.5.3 Dinamika turbopuhala	8						
	3.6	Dinamika motornog mehanizma	8						
	3.7	Regulator	0						
	3.8	³ Visokotlačna pumpa goriva							
	3.9	9 Sustav dizelskog motora							
	3.10	0 Računalno simulacijski model brodskog propulzijskog sustava sa sporohod-							
		nim dvotaktnim dizelskim motorom	5						
4	Mod	del neuronske mreže 3	9						
	4.1	Uvod	9						
	4.2	Umjetni neuron	1						
	4.3	Aktivacijske funkcije	2						
		4.3.1 Logistička sigmoidna funkcija	2						

		4.3.2	Funkcija	hiperboličkog tangensa	45		
		4.3.3	Linearna	a funkcija	45		
		4.3.4	Funkcija	n praga	45		
		4.3.5	Limitira	na linearna funkcija	46		
		4.3.6	Elliot fu	nkcija	47		
		4.3.7	Gaussov	a funkcija	48		
	4.4	Model	umjetnom MLP neuronskom				
		mrežo	m		49		
	4.5	Pristu	p modelir	anju	50		
		4.5.1	Preproce	esiranje podataka	50		
			4.5.1.1	Prikupljanje podataka	50		
			4.5.1.2	Ocjena i odabir podataka, ulazne i izlazne vrijednosti	51		
			4.5.1.3	Priprema seta podataka za treniranje, validaciju i test	52		
			4.5.1.4	Skaliranje i transformacija podataka	52		
		4.5.2	Odabir l	broja skrivenih slojeva i neurona u svakom sloju	53		
		4.5.3	Odabir i	inicijalnih vrijednosti težina	53		
		4.5.4	Proces u	lčenja	54		
		4.5.5	Analiza	rezultata mreže	55		
		4.5.6	Optimiz	acija strukture MLP mreže	55		
			- 1				
5	Mo	delirar	ije neuro	onske mreže na simulacijskom modelu brodskog dizel	l-		
	skog	g mote	ora		57		
	5.1	Osnovni podaci o motoru					
	5.2	Prikuj	oljanje po	dataka iz simulacije	59		
		5.2.1	Histogra	mi svih podataka za koje se vršila simulacija	63		
		5.2.2	Histogra	mi ulaznih simulacijskih podataka, konvergirajući	64		
		5.2.3	Histogra	mi ulaznih simulacijskih podataka, divergirajući	65		
	5.3	B Histogrami ulaznih podataka za treniranje mreže					
	5.4	Histogrami ulaznih podataka za validaciju					
		mreže			67		
	5.5	Histog	grami ulaz	znih podataka za konačni test			
		mreže			67		
5.6 Učenje mreže		e mreže n	a podacima iz simulacije	68			
	5.7	Pregle	d rezultat	ta i provjera pogreške	69		
		5.7.1	Uspored	ba vrijednosti simulacijskih podataka i podataka dobivenih			
			neuronsl	kom mrežom	69		
			5.7.1.1	Usporedba specifične potrošnje $b_{\rm e}$ iz simulacije i dobivene			
				neuronskom mrežom	70		
			5.7.1.2	Usporedba zakretnog momenta na motoru $M_{\rm M}$ iz simula-			
				cije i dobivene neuronskom mrežom	71		
			5.7.1.3	Usporedba brzine vrtnje turbopuhala $n_{\rm TP}$ iz simulacije i			
				dobivene neuronskom mrežom	72		
			5.7.1.4	Maseni protok na puhalu $m_{\text{prot},P}$ iz simulacije i dobiven			
				neuronskom mrežom	73		
			5.7.1.5	Maseni protok na turbini $m_{\text{prot},T}$ iz simulacije i dobiven			
				neuronskom mrežom	74		
			5.7.1.6	Tlak u usisnom kolektor u $p_{\rm UK}$ iz simulacije i dobiven ne-			
				uronskom mrežom	75		

		5.7.1.7	Tlak u ispušnom kolektor u $p_{\rm IK}$ iz simulacije i dobiven ne-	-				
		5.7.1.8	uronskom mrežom \ldots	76				
		5.7.1.9	bivena neuronskom mrežom \ldots	77				
		5.7.1.10	bivena neuronskom mrežom	78				
		5.7.1.11	uronskom mrezom	79 80				
		5.7.1.12	Maksimalna temperatura procesa T_{max} iz simulacije i do- bivena neuronskom mrežom	81				
		5.7.2 Osvrt na	a analizu pogreške	81				
	5.8	Primjer vrijedno	osti neuronske mreže za puno opterećenje motora	82				
	5.9	Primjer vrijedno	osti neuronske mreže za 50% opterećenja motora \ldots	90				
	5.10	Osvrt na dobive	ene rezultate	94				
6	6 Primjena razvijenog modela neuronske mreže za optimiranje uvjeta utilizacije i minimalizaciju specifične po							
	CTOS	Il goriva	niliom nostizania maksimalna	95				
	 6.1 Upravljanje sa ciljem postizanja maksimalne toplinske snage ispušnih plinova							
		zadržavanje kon	stantnog zakretnog momenta i konstantne brzine vrtnje na					
	6.3	motoru Optimiranje rac	la motora za minimalnu emisiju dušikovih oksida	99 103				
7	Zak	ljučak		105				
Bi	bliog	rafija		107				
Po	pis o	oznaka i simbo	la	113				
Po	Popis slika							
Po	Popis tablica							
In	Index							
Ži	Životopis							

1 Uvod

1.1 Sporohodni brodski dizelski motori

Dvotaktni sporohodni brodski dizelski motori sa prednabijanjem imaju niz prednosti zbog svog velikog stupnja djelovanja i pouzdani su, osobito zbog sustava održavanja koje je planirano i napravljeno tako da ga provodi sama posada broda. Zbog manjeg broja okretaja motora dijelovi se manje habaju, a i sporije odvijanje procesa izgaranja povećava njegovu učinkovitost. Prednabijanje motora omogućava povećanje snage motora. Uz to što se povećava snaga motora smanjuje se specifična potrošnja goriva. No sa povećanjem srednjih specifičnih tlakova povećavaju se i maksimalne temperature procesa, što ima utjecaja na naprezanje dijelova motora (kao posljedica termičkih dilatacija) te također i na emisije.

Dvotaktni sporohodni brodski dizelski motori pokreću ne samo brodove, nego i generatore u baznim stanicama za proizvodnju struje. Zbog svojih povoljnih karakteristika, dizelski motori gotovo su neizostavni u propulziji brodova. Pogone brodski vijak direktno preko brodskog osovinskog voda. Stoga su sporohodni dizelski motori ipak najčešći pogonski stroj kod brodova.

Sustav brodskog dizelskog motora mora raditi, uz dopušteno degradiranje performansi, i onda kada se dogodio kvar, ako ga takav režim ne dovodi u opasnost za nastanak veće štete ili ako bi posada bila time ugrožena.

Da bi to bilo izvedivo, potrebno je neprekidno praćenje svih bitnih parametara koji mogu ili ukazati na problem i prije nego se dogodi ili onih koji mogu popraviti performanse samog sustava. Inteligentni sustav mora imati pristup tim podacima, dijagnosticirati probleme, te imati mogućnost upravljanja. Prvi takav sustav uspješno je implementiran 1998. godine u brodski motor MAN B&W 6L60MC.

Elektronsko upravljanje ispušnim ventilima i ubrizgavanjem goriva, te "common rail" sustav omogućili su proizvođačima sporohodnih dizelskih motora Wärtsila (motori serije RT-flex) i MAN (serija ME) mogućnost učinkovitog upravljanja, a sve u svrhu smanjenja emisija i povećanja ukupne efikasnosti i pouzdanosti sustava motora i strojarnice.

Motor je jedna od bitnih komponenti brodskog pogonskog postrojenja, koje mora tijekom ekspolatacije brodu pružati: propulziju, sigurno i pouzdano funkcioniranje broda, te istodobno biti sigurno za posadu, teret i sami brod.

U ovom radu glavne točke koje su se promatrale su bila stacionarna stanja, premda model time nije limitiran samo na stacionarna stanja. Standardni proračuni rijetko kada obuhvaćaju analizu prijelaznih pojava i ponašanje glavnog motora pri promjeni radnih uvjeta, premda postoje i bitni su prilikom modeliranja, osobito pri plovidbi morem u teškim uvjetima ili prilikom nagle promjene opterećenja motora ako radi kao agregat.

Da ne bi došlo do većih kvarova tijekom eksploatacije stroja i havarije, proizvođači motora ugrađuju opremu čija je svrha kontrolirati da tijekom manevara ne dođe do preopterećenja i zaustavljanja glavnog motora. Ograničenja često znače odvijanje prema već unaprijed zadanom programu koji sustav drži dalje od opasnih režima i to sa određenim faktorom sigurnosti. Veći faktor sigurnosti uvijek znači kapacitet koji nije iskorišten.

Boljom regulacijom moglo bi se proširiti područje rada, možda i kratkotrajno, na stanja u kojima bi se inače dogodio "crash stop". Veliki utjecaj na perforanse motora imaju turbopuhalo i sustav regulacije (čija sposobnost da odradi dobro svoj posao dolazi do izražaja pri teškim uvjetima rada).

U gore spomenutoj situaciji ili u slučaju kada dizelski motor služi kao agregat za proizvodnju električne energije, odziv motora i sposobnost naglog preuzimanja velikog opterećenja mogu biti vrlo važni. Problem je još složeniji ako se radi o dizelskom motoru s prednabijanjem, kojemu je potrebno neko vrijeme da pri povećanju opterećenja turbopuhalo ubrza i poveća trenutnu snagu motora. Osim toga, veličina i aranžman usisnih i ispušnih kolektora te izbor turbopuhala znatno utječu na karakteristike motora, kako na statičke tako i na dinamičke. Na odabiru odgovarajućih komponenti uglavnom rade proizvođači, koji mogu provoditi eksperimentalna ispitivanja na prototipovima. To je pouzdana metoda koja, pak, zahtijeva opsežne pripreme i znatna financijska sredstva. Umjesto skupog eksperimentiranja, takva se analiza može provesti primjenom računala i simulacijskih modela koji omogućuju istraživanje situacija koje je teško ostvariti u eksperimentu ili u slučajevima kada bi rizik od štetnog djelovanja na uređaje ili okolinu bio previsok.

Primjenom simulacijskih modela kod brodskoga pogonskog postrojenja može se ostvariti niz ciljeva, poput optimizacije sustava promjenom konfiguracije ili postavkama regulacije.

Simulacijski modeli daju uvid u razne interakcije koje nisu odmah direktno vidljive na realnim sustavima, jer ili su promjene prebrze za postojeće mjerne uređaje, ili je mjesto mjerenja nedostupno. Isto tako, simulacijski modeli omogućavaju razvoj novih virtualnih osjetnika koji ne mjere direktno pojavu koja nas zanima, nego kombinacijom više signala iz dostupnih izvora kreiraju dovoljno precizan signal koji je dostatna zamjena za nedostupni, ili kao dodatni kontrolni osjetnik.

Inteligentni sustav automatizacije mora imati dostupne podatke za nadzor sustava kao i ugrađeno znanje koje mu omogućava da i u najtežim situacijama donosi odluke koje su brze i ispravne. Ponekad to znači i kompletno gašenje sustava, ali sustav mora biti općenito tolerantan na kvarove, prilagođen za razne neželjene situacije i prilagodljiv za nova neželjena stanja.

1.2 Cilj istraživanja

Cilj ovog istraživanja bio je razvoj modela za predviđanje parametara rada brodskog dizelskog motora temeljenog na neuronskim mrežama i njegova moguća implementacija u sustav upravljanja motora. Težište rada baziralo se na istraživanju što efikasnijeg predviđanja radnih parametara. Provjeravala se mogućnost ispitivanja reverzibilnog smjera ispitivanja podataka ili zamjena ulaznih i izlaznih vrijednosti.

Cijeli niz modela koristi se za simulacije u svrhu izračunavanja radnih parametara dizelskog motora i njegovog ponašanja u uvjetima promjenjivih opterećenja. Prema složenosti dijele se na nultodimenzijske, kvazidimenzijske i višedimenzijske (1D, 2D i 3D). U svim modelima promjena u vremenu je automatski uključena. Kvazidimenzijski i višedimenzijski modeli često uključuju i kemijske reakcije izgaranja goriva kao i tvorbu polutanata. Zbog toga postaju složeni i računalno vrlo zahtjevni, ali i nezamjenjivi zbog zadovoljavajuće točnosti numeričkih simulacija. Nezamjenjivi su u predviđanju ponašanja motora u fazi razvoja samog koncepta. Nedostatak tih modela očituje se u relativno dugom vremenu proračuna, znatno dužem nego što se odvija realni proces, te su stoga nedovoljno brzi i nepogodni za predviđanje parametara i implementaciju u sustavima

upravljanja.

Ideja ovoga rada bio je razvoj i implementacija modela neuronskih mreža sa ciljem da novi simulacijski model bude u mogućnosti izvršavati predviđanja u realnom vremenu ili kraće, i da takav model omogući platformu za brzu provjeru novih ideja i koncepata. U tome se djelomično uspjelo.

Pošto svaka simulacija ne treba čitav spektar parametara i zbog pojednostavljenja, nisu se koristili svi parametri koji su bili dostupni. I dalje su se koristili simulacijski modeli koji nisu koristili neuronske mreže u svrhu prikupljanja podataka koji su se pohranili i bili osnova za treniranje, validaciju i test simulacijskih modela koji uključuju primjenu neuronskih mreža.

Svrha razvoja novog simulacijskog modela, bržeg i manje zahtjevnog, jest ubrzani proces odabira odgovarajućeg glavnog pogonskog motora i potrebne opreme za sistem rashlade, kao i ono najbitnije, takav model ima potencijal za implementaciju u sustavima za online optimizaciju rada samog motora.

1.3 Obrazloženje radne hipoteze

U razvojnoj fazi ove disertacije radna hipoteza bazirala se na pretpostavci da je moguće uspješno modelirati i razviti simulacijski model baziran na neuronskim mrežama i takav model primjeniti. U radu se pokazuje da je takva implementacija moguća, ali isto tako da je za uspješno predviđanje parametara potreban pažljivo osmišljen pristup istraživanju, osobito u segmentu prikupljnja podataka, i njihovoj obradi, te pažljivom bilježenju prilikom rada sa samim strukturama mreža.

Podaci za razvoj neuronskih mreža preuzeti su iz raznih simulacijskih modela, raznih mjerenja kao i iskustva iz realnih uvjeta. Takvi podaci su iz raznih izvora pa je tome potrebno posvetiti posebnu pažnju. Neki od tih parametara moraju se prilagoditi kao ulazni podatak za rad sa neuronskom mrežom.

Pokazalo se da neuronske mreže mogu dati precizna predviđanja parametara, ali sa rezervom da preciznost značajno ovisi o prikupljenim podacima, odabiru ulaznih varijabli i da nisu svi parametri jednako precizno predviđeni.

Isto tako u radu je korištena statička neuronska mreža koja se u vremenu prilikom eksploatacije ne mijenja, pa je time limitirana mogućnost online optimizacije same mreže.

1.4 Struktura rada

Rad je podijeljen u sedam poglavlja od kojih prvo poglavlje čini uvod. U uvodu je opisan značaj i način pristupa analizi i modeliranju brodskih pogonskih postrojenja primjenom numeričke simulacije te su definirani ciljevi i svrha rada.

U drugom poglavlju dan je pregled znanstvenih radova i dosadašnjih istraživanja iz područja matematičkog modeliranja motora s unutarnjim izgaranjem te prethodnih radova iz modeliranja sa primjenom neuronskih mreža.

Treće poglavlje obuhvaća teorijske pretpostavke i izvode matematičkih modela za procese u cilindru dizelskog motora, usisnom i ispušnom kolektoru motora, ponašanje turbopuhala, te za dizelski motor u cijelosti.

U četvrtom poglavlju prikazan je opis procesa modeliranja neuronskih mreža, prikupljanje, analiza i predprocesiranje podataka.

U petom poglavlju prikazan je proces modeliranja neuronske mreže na podacima dobivenim iz simulacijskog modela.

Utvrđeno je da se rezultati postignuti simulacijom na računalu dobro poklapaju s rezultatima pri stacionarnom radu odabranoga dizelskog motora, što je preduvjet za ispravnost simulacije pri dinamičkim uvjetima rada dizelskog motora.

U šestom poglavlju je prikazana primjena modela neuronske mreže za postizanje optimalnih uvjeta utilizacije i/ili postizanje minimalne specifične potrošnje.

U sedmom i posljednjem poglavlju, iznesen je zaključak rada. Isto tako, predložena su i područja daljnjeg istraživanja i proširivanja postojećih simulacijskih modela i njihovih komponenti.

2 Prethodna istraživanja

Velik dio radova na temu primjene neuronskih mreža bazira se ili na detekciji pogreške pomoću virtualnih senzora ili predviđanju parametara rada motora.

Neki od znanstvenika koji se bave problematikom predviđanja parametara korištenjem neuronskih mreža ili općenito simulacijama kod brodskih dizelskih motora (sustava upravljanja i kontrole) su od domaćih znanstvenika-istraživača:

Radica u svojoj disertaciji [1] istražuje mogućnosti dijagnostike stanja i samo-optimizaciju rada brodskih dizelskih motora uz pomoć ekspertnih sustava. Razvio je i ekspertni sustav za analizu i dijagnostiku radnih karakteristika dizelskog motora, te dao opis ekspertnih sustava . U disertaciji je dan presjek dosadašnjih istraživanja i postojećeg stanja iz područja dijagnostike ekspertnih sustava. Opisani su dosadašnji razvijeni ekspertni sustavi proizvođača brodskih motora MAN-B&W i Wärtsilä.

U radu Mrakovčić [2] razvijen je matematički model i računalni program za simulaciju procesa u brodskome pogonskom postrojenju tijekom stacionarnih i dinamičkih uvjeta rada. Matematički model temelji se na energetskoj bilanci, bilanci mase, svojstvima radnog medija i konstrukcijskim značajkama pojedinih komponenti simuliranog postrojenja. Posebno je analizirano ponašanje brodskog pogonskog motora i brodskog rashladnog sistema. Dio simulacijskog djela korišten je i u ovom radu.

Senčić u radu [3] razvija kompletan 3D model predviđanja stvaranja čađe u velikom brodskom sporohodnom motoru. U isti model ugrađen je i model teškog goriva i model za čađu, a izvršena je i korekcija parametara mlaza. Izvršene su simulacije na raznim oblicima proračunskih mreža. Validacija modela provedena je na komori izgaranja sa konstantnim volumenom, na vozilskom dizelskom motoru i velikom sporohodnom brodskom motoru.

U radu [4] dan je prikaz rezultata istraživanja mogućnosti primjene umjetnih neuronskih mreža (ANN) u obradi senzorskih signala za potrebe sustava upravljanja i dijagnostike brodskih dizelskih procesa. Došlo se do podataka o potrebnom broju mjernih, odnosno nadzornih i upravljačkih varijabli po pojedinim podsustavima i vrstama signala (temperature, tlakovi, protoci, razine i ostali) za veliki brodski dvotaktni porivni dizelski motor.

U radu [5] se istražuju nove tehnike, metode i postupci korištenjem neizrazite logike, ekspertni sustavi, umjetne neuronske mreže sa ciljem unapređenja dijagnostike brodskog dizelskog motora za vrijeme njegove eksploatacije. Predlaže se sustav upravljanja koji ima sposobnost prilagođavanja kvarovima nastalim za vrijeme rada.

U radu [6] prikazana je upravljačka shema brzine motora sa emisijskim ograničenjima. Shema koristi specijalizirano treniranje neurokontrolera preko direktnog modela motora izvedenog kao neuronska mreža. Zanimljivost rada je u primjeni neuronskih mreža i za modeliranje motora kao i za njegovo upravljanje.

Rad [7] istražuje mogućnost korištenja umjetne neuronske mreže (ANNs) u kombinaciji s genetskim algoritmima za optimizaciju postavki rada dizelskog motora u cilju zadovoljenja propisa o emisijama štetnih tvari, uz zadržavanje iste potrošnje, ili čak smanjenje. ANN, korištene kao simulacijski alat, primale ulaze koji su sadržavali radne parametre, i izlaze koji su sadržavali emisije i potrošnju goriva. ANN se koristi kao evaluacijska funkcija optimizacijskog procesa primjenom genetskog algoritma. U radu [8] neuronske mreže za ulazne parametre tlaka ubrizgavanja, brzine vrtnje motora i položaja ručice goriva, predviđaju moment na motoru, snagu, specifičnu potrošnju goriva, protok goriva i emisije dizelskog motora (SO_2, CO_2, NO_x) kao i stupanj čađenja (%N).

Istraživanje samih parametara neuronske mreže i strukture, odabir broja slojeva i aktivacijske funkcije sa primjenom na predviđanje emisija dizelskog motora opisano je u radu [9].

Model brodskog dizelskog motora namjenjen za upravljanje u realnom vremenu izveden je u radu [10]. Takav sustav se koristi za razvoj i analizu algoritama upravljanja u simulacijskim sustavima sa hardverom u petlji. U radu se koristi hibridni model. Prvo je razvijen model sa kvazi-stacionarnim stanjima, a zatim je nadodana komponenta nestacionarnosti i korekcije primjenom neuronske mreže.

U radu [11] spominju se razlozi korištenja neuronskih mreža za uštedu računalnih resursa, a za postizanje točnosti višedimenzionalnih CFD proračuna ili eksperimentalnih podataka. Pri tome, dano je više metoda kojima se poboljšavaju predviđanja neuronskih mreža. Jedna od metoda je i uključivanje modela izgaranja u samu transfer funkciju neuronske mreže.

U radu [12] predviđa se indicirani moment na jednocilindričnom dizelskom motoru iz kutne pozicije koljenaste osovine i trenutne brzine. Time se omogućava dijagnostika sa jeftinim virtualnim senzorom.

Autori rada [13] koriste neuronsku mrežu (nelinearni autoregresijski model NLARX) za predstavljanje tlaka u usisnom kolektoru i specifične potrošnje goriva. Ulazni parametri su podizaj usisnih ventila, ispušnih ventila, EGR-a, VGT, moment na motoru i brzina.

U radu [14] autori primjenjuju neuronsku mrežu za dijagnosticiranje greške na sustavu hlađenja kod brodskih motora.

Predviđanje emisije NO_x -a preko tlaka u cilindru primjenom RBF neuronskih mreža spominje se u radu [15].

He i Rutland u radu [16] primjenjuju neuronske mreže za modeliranje dizelskih motora sa prednabijanjem i direktnim ubizgavanjem, dok u radu [17] spominju izradu modela cilindra primjenom neuronskih mreža.

Caterpilar ima više patenata koji uključuju primjenu neuronskih mreža, kao npr. neuronske mreže za korekciju vrijednosti dobivenih iz postojećih modela za predviđanje emisija NOx.

3 Matematički model dizelskog motora

Sustav dizelskog motora sa unutarnjim izgaranjem i prednabijanjem sastoji se od više međusobno povezanih komponenti koje se mogu promatrati na dva načina – svaka zasebno, ili u međusobnoj ovisnosti kao sustav [2]. Komponente dizelskog motora s prednabijanjem prikazane su na slici 3.1. Jedna od najvažnijih komponenti cijelog sustava dizelskog motora je regulator. Regulacija se temelji na uspoređivanju trenutne brzine vrtnje u odnosu na zadanu vrijednost i posljedično, regulaciju količine ubrizganog goriva u cilindar motora. Izgaranjem goriva u cilindru motora razvija se zakretni moment. Zakretni moment dovodi do promjene brzine vrtnje, što je ovisno od više parametara a to su: trenutni moment potreban za pogon trošila, tj. potrošača, gubici u motoru i moment tromosti rotirajućih masa.

Otvaranjem ispušnog ventila, ispušni plinovi nastali izgaranjem u cilindru odlaze u ispušni kolektor u kojem se skupljaju, a potom se iz ispušnog kolektora odvode na turbinu turbopuhala. Radijalna je turbina na ispušne plinove spojena vratilom na puhalo, koje usisava zrak iz atmosfere i komprimira ga na viši tlak. Prilikom kompresije, uz povećanje tlaka, javlja se i povećanje temperature komprimiranog zraka, pa se zrak nakon kompresije, a prije ulaska u usisni kolektor i cilindre, hladi u hladnjaku. Energija oslobođena izgaranjem goriva u cilindru motora prenosi se preko klipova i ojnica na koljenasto vratilo koje pogoni radni stroj. Cjelokupni matematički model dizelskog motora sa prednabijanjem sastavljen je od zasebnih matematičkih modela svih sastavnih komponenti. Sve komponente koje čine cjelokupni sastav određenog motora uzajamno su povezane vezama za prijenos mase i energije.



Slika 3.1: Shema dizelskog motora s prednabijanjem [2]

3.1 Jednadžbe očuvanja mase i energije

Dinamički rad dizelskog motora simuliran je primjenom kvazistacionarnog modela. Karakteristika ovog modela je da u kontrolnim volumenima (cilindri, usisni i ispušni kolektor) pretpostavlja homogeno stanje u promatranom trenutku. Promjene stanja u pojedinim kontrolnim volumenima opisane su običnim diferencijalnim jednadžbama prvog reda za očuvanje mase i energije. Medij koji ustrujava u kontrolni volumen miješa se u homogenu smjesu s medijem koji se nalazi otprije u tom volumenu. Kod promatranja i praćenja dinamičkih uvjeta rada motora, jednadžbe za očuvanje mase i energije potrebno je dopuniti jednadžbama koje definiraju kinematiku i dinamiku svih komponenti sustava. U proračunu se tlak, temperatura i pretičak zraka uzimaju kao vremenske funkcije, dok se zbog homogenosti smjese iz razmatranja izuzimaju polja temperature, tlaka i brzina.

Promjena mase dm po kutu zakreta koljenastog vratila d φ u promatranom kontrolnom volumenu, određena je masom medija koja ulazi d m_u i izlazi d m_i iz kontrolnog volumena, masom dovedenoga goriva d m_g , dodatnog zraka d m_{dz} i masom medija koja zbog propuštanja izlazi izvan granica kontrolnog volumena d m_{pr} , a prikazana je jednadžbom:

$$\frac{\mathrm{d}m}{\mathrm{d}\varphi} = \frac{\mathrm{d}m_{\mathrm{u}}}{\mathrm{d}\varphi} + \frac{\mathrm{d}m_{\mathrm{i}}}{\mathrm{d}\varphi} + \frac{\mathrm{d}m_{\mathrm{g}}}{\mathrm{d}\varphi} + \frac{\mathrm{d}m_{\mathrm{dz}}}{\mathrm{d}\varphi} + \frac{\mathrm{d}m_{\mathrm{pr}}}{\mathrm{d}\varphi}$$
(3.1)

Jednadžba očuvanja energije temelji se na prvom glavnom stavku termodinamike, koji se u diferencijalnom obliku može napisati kao:

$$\mathrm{d}Q = \mathrm{d}U + p\,\mathrm{d}V\tag{3.2}$$

$$dU = d(mu) = u \, dm + m \, du \tag{3.3}$$

Uvrštavanjem jednadžbe (3.3) u (3.2) slijedi:

$$dQ = u \, dm + m \, du + p \, dV \tag{3.4}$$

Za medij u kontrolnom volumenu postavlja se sljedeća bilanca energije:

$$\mathrm{d}Q = \sum_{i} \mathrm{d}Q_{i} + \sum_{j} h_{j} \,\mathrm{d}m_{j} \tag{3.5}$$

gdje je $\sum_{j} h_j \cdot dm_j$ osjetna toplina medija koji prestrujava, dok je član $\sum_{i} dQ_i$ toplina koja se izmjenjuje između radnog medija i granica kontrolnog volumena, a sastoji se od topline izgaranja goriva Q_g i topline koja se izmjenjuje sa stijenkama Q_{st} , odnosno:

$$\sum_{i} \mathrm{d}Q_{i} = \mathrm{d}Q_{\mathrm{g}} + \mathrm{d}Q_{\mathrm{st}}$$
(3.6)

Iz izraza (3.4) i (3.5) slijedi:

$$m \,\mathrm{d}u + u \,\mathrm{d}m = \sum_{i} \mathrm{d}Q_{i} + \sum_{j} h_{j} \,\mathrm{d}m_{j} - p \,\mathrm{d}V \tag{3.7}$$

Jednadžba stanja idealnog plina glasi:

$$pV = mRT \tag{3.8}$$

Specifična unutarnja energija i plinska konstanta smjese zraka i produkata izgaranja funkcije su temperature, tlaka i pretička zraka:

$$u = f(T, p, \lambda) \tag{3.9}$$

$$R = f(T, p, \lambda) \tag{3.10}$$

Diferenciranjem jednadžbi (3.9) i (3.10) dobije se:

$$du = \frac{\partial u}{\partial T} dT + \frac{\partial u}{\partial p} dp + \frac{\partial u}{\partial \lambda} d\lambda$$
(3.11)

$$dR = \frac{\partial R}{\partial T} dT + \frac{\partial R}{\partial p} dp + \frac{\partial R}{\partial \lambda} d\lambda$$
(3.12)

Uvrštavanjem jednadžbi (3.8), (3.11) i (3.12) u jednadžbu (3.7), nakon sređivanja, slijedi jednadžba za promjenu temperature medija u kontrolnom volumenu obzirom na kut koljena koljenastog vratila:

$$\frac{\mathrm{d}T}{\mathrm{d}\varphi} = \frac{\frac{1}{m} \left[-p \frac{\mathrm{d}V}{\mathrm{d}\varphi} + \sum_{i} \frac{\mathrm{d}Q_{i}}{\mathrm{d}\varphi} + \sum_{j} \left(h \frac{\mathrm{d}m}{\mathrm{d}\varphi} \right)_{j} - u \frac{\mathrm{d}m}{\mathrm{d}\varphi} - m \left(\frac{\partial u}{\partial \lambda} \right) \frac{\mathrm{d}\lambda}{\mathrm{d}\varphi} \right] - C}{\frac{\partial u}{\partial T} + \frac{A}{B} \frac{p}{T} \frac{\partial u}{\partial p}}$$
(3.13)

gdje su:

$$A = 1 + \frac{T}{R} \frac{\partial R}{\partial T}$$

$$B = 1 - \frac{p}{R} \frac{\partial R}{\partial p}$$

$$C = \frac{p}{B} \frac{\partial u}{\partial p} \left[\frac{1}{m} \frac{\mathrm{d}m}{\mathrm{d}\varphi} - \frac{1}{V} \frac{\mathrm{d}V}{\mathrm{d}\varphi} + \frac{1}{R} \left(\frac{\partial R}{\partial \lambda} \right) \frac{\mathrm{d}\lambda}{\mathrm{d}\varphi} \right]$$
(3.14)

Članovi A, B i C iz (3.14) sadrže utjecaj kompresibilnosti i disocijacije plinova izgaranja, tj. svojstava idealnog plina. Budući da kod dizelskih motora disocijacija rijetko nastupa zbog maksimalnih temperatura procesa nižih od 2000 K, a kompresibilnost plina je slabo izražena, svojstva realnog plina mogu se aproksimirati svojstvima idealnog plina. U tom slučaju vrijedi u = u(T) i $\partial u/\partial p = 0$, zbog čega bi se članovi A, B i C zanemarili te bi jednadžba za promjenu temperature u ovisnosti o kutu koljena koljenastog vratila glasila:

$$\frac{\mathrm{d}T}{\mathrm{d}\varphi} = \frac{1}{m\frac{\partial u}{\partial T}} \left[-p\frac{\mathrm{d}V}{\mathrm{d}\varphi} + \sum_{i} \frac{\mathrm{d}Q_{i}}{\mathrm{d}\varphi} + \sum_{j} h_{j} \frac{\mathrm{d}m_{j}}{\mathrm{d}\varphi} - u\frac{\mathrm{d}m}{\mathrm{d}\varphi} - m(\frac{\mathrm{d}u}{\mathrm{d}\lambda})\frac{\mathrm{d}\lambda}{\mathrm{d}\varphi} \right]$$
(3.15)

3.2 Cilindar motora

Kontrolni volumen cilindra dizelskog motora omeđen je stijenkama cilindra i površinom čela klipa koji se giba (Slika 3.2). Na temelju prije izvedenih jednadžbi može se napisati diferencijalna jednadžba promjene temperature u cilindru, ovisno o kutu koljena koljenastog vratila:

$$\frac{\mathrm{d}T_{\mathrm{c}}}{\mathrm{d}\varphi} = \frac{1}{m_{\mathrm{c}}\frac{\partial u}{\partial T}} \left[-p\frac{\mathrm{d}V}{\mathrm{d}\varphi} + \sum_{i} \frac{\mathrm{d}Q_{i}}{\mathrm{d}\varphi} + \sum_{j} h_{j}\frac{\mathrm{d}m_{j}}{\mathrm{d}\varphi} - u\frac{\mathrm{d}m}{\mathrm{d}\varphi} - m(\frac{\mathrm{d}u}{\mathrm{d}\lambda})\frac{\mathrm{d}\lambda}{\mathrm{d}\varphi} \right]$$
(3.16)



Slika 3.2: Kontrolni volumen cilindra motora [2]

Djelovanjem tlaka u cilindru ostvaruje se rad definiran kao:

$$\frac{\mathrm{d}W_{\mathrm{c}}}{\mathrm{d}\varphi} = p_{\mathrm{c}}\frac{\mathrm{d}V_{\mathrm{c}}}{\mathrm{d}\varphi} \tag{3.17}$$

Tlak u cilindru određuje se iz jednadžbe stanja idealnog plina:

$$p_{\rm c} = \frac{m_{\rm c} T_{\rm c} R_{\rm c}}{V_{\rm c}} \tag{3.18}$$

Trenutni volumen cilindra izračunava se iz kinematike koljenastog mehanizma. Ovisnost položaja klipa o kutu zakreta koljenastog vratila φ definirana je jednadžbom:

$$x = r + l - r\cos\varphi - l\cos\beta = r \left(1 - \cos\varphi\right) + l \left(1 - \sqrt{1 - \lambda_{\rm m}^2 \sin^2\varphi}\right)$$
(3.19)

gdje je r polumjer koljenastog vratila, l duljina ojnice, a $\lambda_m = r/l$ omjer polužja koljenastog mehanizma. Volumen cilindra ispunjenog radnim medijem za neki položaj x klipa je:

$$V_{\rm c} = \frac{d_{\rm c}^2 \pi}{4} x + V_0 \tag{3.20}$$

gdje je V_0 kompresijski prostor. Ako je $V_{\rm s} = \frac{d_{\rm c}^2 \pi}{2} r$ stapajni volumen, a $\varepsilon = \frac{V_{\rm s} + V_0}{V_0}$ geometrijski stupanj kompresije, volumen cilindra je $V_{\rm c} = \frac{V_{\rm s}}{2r} x + \frac{V_{\rm s}}{\varepsilon - 1} = \frac{V_{\rm s}}{2} \left(\frac{x}{r} + \frac{2}{\varepsilon - 1}\right)$, što skupa s jednadžbom (3.19) daje izraz:

$$V_{\rm c} = \frac{V_{\rm s}}{2} \left[\frac{2}{\varepsilon - 1} + (1 - \cos\varphi) + \frac{1}{\lambda_{\rm m}} \left(1 - \sqrt{1 - \lambda_{\rm m}^2 \sin^2\varphi} \right) \right]$$
(3.21)

Brzina promjene volumena cilindra dobiva se diferenciranjem gornjeg izraza po kutu koljena koljena
stog vratila φ :

$$\frac{\mathrm{d}V_{\mathrm{c}}}{\mathrm{d}\varphi} = \frac{V_{\mathrm{s}}}{2} \left[\sin\varphi + \lambda_{\mathrm{m}} \frac{\sin\varphi \ \cos\varphi}{\sqrt{1 - \lambda_{\mathrm{m}}^2 \sin^2\varphi}} \right]$$
(3.22)

3.2.1 Prijelaz topline u cilindru

Prijelaz topline u cilindru odvija se preko površine klipa, glave cilindra i košuljice cilindra. Temperaturno polje stijenki je nestacionarno i nehomogeno tako da koeficijenti prijelaza topline imaju različite vrijednosti unutar cilindra. Stoga je potrebno, prilikom određivanja ukupne oduzete ili predane topline radnom mediju, izračunati srednje koeficijente prijelaza topline. Brojni znanstveni radovi bave se problematikom određivanja koeficijenata prijelaza topline, npr. u [60] dat je prikaz eksperimentalno određenih empirijskih jednadžbi za koeficijent konvektivnog prijelaza topline na stijenkama cilindara motora, usisnim i ispušnim kolektorima te kanalima u glavi motora. Jedna od češće primjenjivanih jednadžbi može se naći u [61] i glasi:

$$\alpha_{\rm c} = 130, 5d_{\rm c}^{-0.2} p_{\rm c}^{0.8} T_{\rm c}^{-0.53} \left[C_1 c_{\rm m} + C_2 \frac{V_{\rm s} T_{\rm c,UZ}}{p_{\rm c,UZ} V_{\rm c,UZ}} \left(p_{\rm c} - p_{\rm cK} \right) \right]$$
(3.23)

gdje su: p - tlak [bar], $C_1 = 6, 18 + 0, 417c_{\text{vr}}/c_{\text{m}}$ -tijekom izmjene radnog medija, $C_1 = 2, 28 + 0, 308c_{\text{vr}}/c_{\text{m}}$ - tijekom kompresije ili ekspanzije, $C_2 = 0,00324 \text{ m s}^{-1} \text{ K}^{-1}$ - za dizelske motore s izravnim ubrizgavanjem i $C_2 = 0,00622 \text{ m s}^{-1} \text{ K}^{-1}$ - za dizelske motore s pretkomorom.

Nešto jednostavniju jednadžbu za određivanje koeficijenta prijelaza topline prikazao je Hohenberg u [62]:

$$\alpha_{\rm c} = C_1 V_{\rm c}^{-0.06} p_{\rm c}^{0.8} T_{\rm c}^{-0.4} \left(c_{\rm m} + C_2 \right)^{0.8} \tag{3.24}$$

gdje su: p_c - tlak izražen u bar-ima, $C_1 = 130$, $C_2 = 1, 4$. Pri korištenju ove jednadžbe, uzima se da je površina za prijelaz topline jednaka izloženoj površini stijenke cilindra uvećana za dio površine boka klipa do prvog klipnog prstena:

$$A_{\rm c} = A_{{\rm c},i} + 2d_{\rm c}\pi \frac{h_{\rm k}}{3} \tag{3.25}$$

gdje je h_k visina boka klipa od čela do prvog klipnog prstena.

3.2.2 Propuštanje radnog medija

Ukoliko su klipni prstenovi ispravni i ako je brtvljenje na sjedištima ventila zadovoljavajuće, propuštanje radnog medija iz cilindra $(dm_{\rm pr})$, tijekom rada motora, može se zanemariti. Propuštanje radnog medija iz procesa može biti osjetno, npr. kod starta hladnog motora kada je brzina vrtnje mala, a zazori su relativno veliki. Smanjenje propuštanja radnog medija može se postići korištenjem posebnog ulja za podmazivanje koje se tijekom rada motora ubrizgava direktno na stijenke cilindra. Na taj način smanjuje se trenje klipnih prstenova na stijenkama cilindra, te se poboljšava brtvljenje. Opisani način smanjenja propuštanja često se koristi kod brodskih sporohodnih dvotaktnih dizelskih motora.

U numeričkim simulacijama dizelskih motora bilo koje vrste i namjene, masa ubrizganog cilindarskog ulja koje je sastavni sudionik procesa izgaranja, može se zanemariti jer je riječ o neznatnim količinama koje imaju mali utjecaj na bilancu energije. Sukladno tome, i u ovoj se simulaciji zanemaruje masa ubrizganog ulja.

3.2.3 Kompresija i ekspanzija

Tijekom kompresije i ekspanzije radnog medija uzima se, uz vrlo malu pogrešku, da je masa u cilindru konstantna. Dakle, tijekom tih faza nema izmjene radnog medija niti se u cilindar dovodi gorivo. Sukladno tome slijedi:

$$\frac{\mathrm{d}m_{\mathrm{c}}}{\mathrm{d}\varphi} = 0 \; , \; \frac{\mathrm{d}\lambda_{\mathrm{c}}}{\mathrm{d}\varphi} = 0 \; , \; \frac{\mathrm{d}Q_{\mathrm{g}}}{\mathrm{d}\varphi} = 0 \tag{3.26}$$

Uvrštavajući vrijednosti iz (3.26) u jednadžbu (3.16) dobije se:

$$\frac{\mathrm{d}T_{\mathrm{c}}}{\mathrm{d}\varphi} = \frac{1}{m_{\mathrm{c}}\left(\frac{\partial u}{\partial T}\right)_{\mathrm{c}}} \left[-\frac{p_{\mathrm{c}} \,\mathrm{d}V_{\mathrm{c}}}{\mathrm{d}\varphi} + \frac{\mathrm{d}Q_{\mathrm{st,c}}}{\mathrm{d}\varphi} \right]$$
(3.27)

Ako se tijekom ekspanzije u cilindar dovodi zrak za upućivanje, tada je:

$$\frac{\mathrm{d}m_{\mathrm{c}}}{\mathrm{d}\varphi} = \frac{\mathrm{d}m_{\mathrm{dz}}}{\mathrm{d}\varphi} \tag{3.28}$$

$$\frac{\mathrm{d}T_{\mathrm{c}}}{\mathrm{d}\varphi} = \frac{1}{m_{\mathrm{c}} \left(\frac{\partial u}{\partial T}\right)_{\mathrm{c}}} \left[-\frac{p_{\mathrm{c}} \mathrm{d}V_{\mathrm{c}}}{\mathrm{d}\varphi} + \sum_{i} \frac{\mathrm{d}Q_{\mathrm{st,c}}}{\mathrm{d}\varphi} + h_{\mathrm{dz}} \frac{\mathrm{d}m_{\mathrm{dz}}}{\mathrm{d}\varphi} - u_{\mathrm{c}} \frac{\mathrm{d}m_{\mathrm{dz}}}{\mathrm{d}\varphi} - m_{\mathrm{c}} \left(\frac{\mathrm{d}u}{\mathrm{d}\lambda}\right)_{\mathrm{c}} \frac{\mathrm{d}\lambda_{\mathrm{c}}}{\mathrm{d}\varphi} \right]$$
(3.29)

3.2.4 Izgaranje

Osnovni zadatak u radnom procesu dizelskog motora je stvoriti pogodne uvjete za samozapaljenje smjese zraka i para goriva. Da bi se taj zadatak postigao, mora se osigurati odgovarajuće visoka kompresija zraka (za motore s prednabijanjem), stvaranje vrtloga pri punjenju cilindara svježim zrakom i visokim tlakom ubrizgavanja goriva radi postizanja što bržeg i kvalitetnijeg miješanja goriva i zraka u homogenu gorivu smjesu.

Kod dizelskog motora postoji određeni vremenski odmak u periodima ubrizgavanja goriva i upaljivanja gorive smjese. Taj vremenski odmak naziva se zakašnjenje paljenja. Unutar perioda zakašnjenja paljenja odvijaju se procesi raspada mlaza goriva u sitne kapljice, te isparavanje istih. Kada se steknu pogodni uvjeti, dolazi do upaljivanja para goriva u smjesi sa zrakom. Izgaranje goriva koje je isparilo u vremenu zakašnjenja paljenja odvija se vrlo brzo pri čemu se intenzivno oslobađa toplina. Taj početni dio procesa izgaranja naziva se homogenim izgaranjem. Oslobođena toplina dijelom se koristi za isparavanje preostalih kapljica goriva, pri čemu se brzina i intenzitet izgaranja smanjuju. Procesi istovremenog isparavanja goriva i izgaranja nastavljaju se sve do završetka izgaranja, a taj se proces naziva difuzijskim izgaranjem.

Od početaka istraživanja motora s unutarnjim izgaranjem do danas, razvijeni su različiti numerički modeli za opis i analizu izgaranja u cilindru motora.

Prema [63] i [64] ti se modeli mogu podijeliti u tri glavne skupine:

- 1. nultodimenzionalni modeli,
- 2. kvazidimenzionalni modeli,
- 3. multidimenzionalni modeli.

U ovom se radu koristi nultodimenzionalni model opisa izgaranja u cilindru motora. Nultodimenzionalni model koristi opis procesa izgaranja po Vibeu, koji je izveden analizom izgaranja u benzinskom motoru. Intenzitet oslobađanja topline i brzina izgaranja prikazuju se slijedećim izrazima:

$$Q_{\rm g} = f\left(\varphi\right) = x_{\rm g} m_{\rm g} H_{\rm d} \eta_{\rm izg} \tag{3.30}$$

$$x_{\rm g} = \frac{Q_{\rm g}}{m_{\rm g} H_{\rm d} \eta_{\rm izg}} = 1 - \exp\left(-C \left(\frac{\varphi - \varphi_{\rm PI}}{\varphi_{\rm TI}}\right)^{m+1}\right)$$
(3.31)

$$\frac{\mathrm{d}x_{\mathrm{g}}}{\mathrm{d}\varphi} = \mathcal{C} \ (m+1) \ \left(\frac{\varphi - \varphi_{\mathrm{PI}}}{\varphi_{\mathrm{TI}}}\right)^{m} \exp\left(-\mathcal{C} \ \left(\frac{\varphi - \varphi_{\mathrm{PI}}}{\varphi_{\mathrm{TI}}}\right)^{m+1}\right)$$
(3.32)

gdje je C konstanta i iznosi 6,901.

Iz jednadžbe (3.31) uočljivo je kako se oslobađanje topline odvija prema eksponencijalnoj funkciji, pri čemu Vibeov eksponent m određuje mjesto najvećeg intenziteta oslobađanja topline (Slika 3.3). Stupanj djelovanja η_{izg} uzima u obzir gubitke zbog disocijacije i nepotpunog izgaranja goriva.

3.2.5 Zakašnjenje paljenja

Od početka dobave visokotlačne pumpe goriva do početka izgaranja odvija se nekoliko različitih procesa koji imaju za posljedicu zakašnjenje paljenja gorive smjese u cilindru motora. Naime, s početkom dobave goriva raste tlak u cjevovodu između visokotlačne pumpe goriva i rasprskača. Nakon što tlak na rasprskaču prijeđe određenu, izvedbom i ka-rakteristikama rasprskača unaprijed definiranu vrijednost, započinje ubrizgavanje goriva u cilindar motora. Mlaz goriva miješa se sa zrakom koji je zagrijan tijekom kompresije, pri čemu dolazi do isparivanja goriva iz rubnih područja mlaza. Ako su zadovoljeni uvjeti, stvorena će se smjesa isparenog goriva i zraka upaliti sama od sebe.

Trenutak početka izgaranja ovisi o tri parametra:

- a) O početku dobave visokotlačne pumpe goriva $\varphi_{\rm PD}$,
- b) O vremenu širenja tlačnog vala do početka ubrizgavanja $\Delta \varphi_{\rm PU}$ i



Slika 3.3: Udio izgorenog goriva i brzina izgaranja prema Vibeu

c) O zakašnjenju paljenja
 $\varDelta \varphi_{\rm ZP}.$ Njihova međuovisnost definira se kao:

$$\varphi_{\rm PI} = \varphi_{\rm PD} + \Delta \varphi_{\rm PU} + \Delta \varphi_{\rm ZP} \tag{3.33}$$

Vrijeme između početka dobave visokotlačne pumpe goriva i početka ubrizgavanja goriva u cilindar motora naziva se zakašnjenje ubrizgavanja ($\Delta \varphi_{\rm PU}$), a definirano je vremenom potrebnim za širenje tlačnog vala duž visokotlačnog cjevovoda goriva duljine $L_{\rm cjg}$:

$$\Delta \varphi_{\rm PU} = \frac{360 \ n_{\rm M} \ L_{\rm cjg}}{a_{\rm g}} \tag{3.34}$$

gdje je $a_{\rm g}$ brzina zvuka za gorivo u visokotlačnom cjevovodu.

Kako su veličine L_{cjg} i a_g konstantne, promjena zakašnjenja ubrizgavanja goriva može se izraziti u funkciji brzine vrtnje motora:

$$\Delta \varphi_{\rm PU} = \frac{360 \ n_{\rm M} \ L_{\rm cjg}}{a_{\rm g}} \tag{3.35}$$

$$\Delta \varphi_{\rm PU} = \Delta \varphi_{\rm PU,0} \frac{n_{\rm M}}{n_{\rm M,0}} \tag{3.36}$$

Zakašnjenje paljenja $\Delta \varphi_{\rm ZP}$ definira se jednadžbom koju je izveo Sitkei [65]:

$$\tau_{\rm ZP} = 0,5 + \exp\left(\frac{3,92782}{T_{\rm c,ZP}}\right) \left(0,1332p_{\rm c,ZP}^{-0,7} + 4,637p_{\rm c,ZP}^{-1,8}\right) 10^{-3} \ s \tag{3.37}$$

Jednadžba vrijedi za dizelsko gorivo sa cetanskim brojem 52, dok je za dizelsko gorivo s drugom vrijednosti cetanskog broja potrebna ekstrapolacija gornje jednadžbe.

3.2.6 Potpunost izgaranja

Kod naglog porasta momenta tereta, regulator motora detektira smanjenje brzine vrtnje i, ovisno o veličini promjene brzine, određuje potrebnu količinu goriva za ubrizgavanje u cilindar. U tim prijelaznim razdobljima (tranzijentima), pretičak zraka u cilindru može opasti ispod vrijednosti 1, što dovodi do nepotpunog izgaranja, odnosno do pojave čađe. Nepotpuno izgaranje umanjuje snagu motora [64].

Pojava čađe ovisi o mnogim čimbenicima, ali najviše od pretička zraka i temperature. Također je bitno naglasiti da ne postoji točno definirana granica kod koje započinje pojava čađe, tako da se kod numeričkih simulacija koje se odnose na čađu moraju usvojiti neke grube aproksimacije. Drugi problem vezan uz čađu je činjenica da se ona može mjeriti samo u trenutku otvaranja ispušnih ventila, tako da je teško predvidjeti i izmjeriti njenu promjenu tijekom procesa, te stoga nije moguće razviti pouzdan računalni model.

Pri modeliranju izgaranja u cilindru dizelskog motora potrebno je definirati oslobođenu toplinsku energiju izgaranjem u ovisnosti od pretička zraka. Stupanj djelovanja izgaranja opisuje potpunost oslobađanja raspoložive energije goriva. Definira se kao:

$$\eta_{\rm izg} = \frac{Q_{\rm g,pr}}{m_{\rm g,pr}H_{\rm d}} \tag{3.38}$$

Teorijski stupanj djelovanja izgaranja je:

$$\eta_{\rm izg} \approx \lambda \quad {\rm za} \ \lambda \le 1 \tag{3.39}$$

$$\eta_{\rm izg} = 1 \quad {\rm za} \ \lambda > 1 \tag{3.40}$$

Teorijski stupanj djelovanja izgaranja odgovara uvjetima kada se za miješanje goriva i zraka na raspolaganju ima dovoljno vremena, no kod dizelskih je motora vrijeme za pripremu gorive smjese i izgaranje ograničeno. Granične vrijednosti pretička zraka za pojavu čađe najčešće su dobivene raznim eksperimentalnim ispitivanjima. U radu [66] izvršena su ispitivanja na manjim motorima, a dobivene su slijedeće granične vrijednosti pretička zraka za pojavu čađe:

- $\lambda_{\rm RB} = 2,05$ za motor s mirnom komorom,
- $\lambda_{\rm RB} = 1,25$ za motor s većim vrtloženjem zraka i
- $\lambda_{\rm RB} = 1,18$ za motor s pretkomorom.

Iz istraživanja je proizašla slijedeća empirijska jednadžba za određivanje stupnja djelovanja izgaranja kod poznatog graničnog pretička zraka $\lambda_{\rm RB}$ za pojavu čađe:

- $\eta_{izg} = 1 \text{ za } \lambda \geq \lambda_{RB}$
- $\eta_{\text{izg}} = a\lambda \exp(c\lambda) b \text{ za } \lambda_{\text{RB}} > \lambda > 1$
- $\eta_{izg} = 0,95\lambda + d \text{ za } \lambda \leq 1$

gdje su koeficijenti a, b, c i d definirani izrazima:

$$a = \frac{0,05 - d}{\lambda_{\rm RB} \exp\left(c\lambda_{\rm RB}\right) - \exp\left(c\right)} \tag{3.41}$$

$$b = a \exp(c) - 0,95 - d \tag{3.42}$$

$$c = -\frac{1}{\lambda_{\rm RB}} \tag{3.43}$$

$$d = -0,0375 - \frac{\lambda_{\rm RB} - 1,17}{15} \tag{3.44}$$

3.2.7 Izmjena radnog medija kod četverotaktnog motora

Tijekom izmjene radnog medija cilindar motora je spojen s usisnim ili ispušnim kolektorom, ovisno o tome jesu li otvoreni usisni ili ispušni ventil. U periodu dok su istovremeno otvoreni i usisni i ispušni ventil, cilindar je u vezi s oba kolektora. Dok traje proces izmjene radnog medija, u cilindru nema izgaranja, pa jednadžba promjene temperature u ovisnosti o kutu koljena koljenastog vratila glasi:

$$\frac{\mathrm{d}T_{\mathrm{c}}}{\mathrm{d}\varphi} = \frac{1}{m_{\mathrm{c}}\left(\frac{\partial u}{\partial T}\right)_{\mathrm{c}}} \left[-\frac{p_{\mathrm{c}} \,\mathrm{d}V_{\mathrm{c}}}{\mathrm{d}\varphi} + \frac{\mathrm{d}Q_{\mathrm{st,c}}}{\mathrm{d}\varphi} + h_{\mathrm{u}}\frac{\mathrm{d}m_{\mathrm{c,u}}}{\mathrm{d}\varphi} + h_{\mathrm{i}}\frac{\mathrm{d}m_{\mathrm{c,i}}}{\mathrm{d}\varphi} - u_{\mathrm{c}}\frac{\mathrm{d}m_{\mathrm{c}}}{\mathrm{d}\varphi} - m_{c}\left(\frac{\mathrm{d}u}{\mathrm{d}\lambda}\right)_{\mathrm{c}}\frac{\mathrm{d}\lambda_{\mathrm{c}}}{\mathrm{d}\varphi} \right]$$

$$(3.45)$$

Ukupna promjena mase jednaka je zbroju promjena masa koje ulaze ili izlaze iz cilindra:

$$\frac{\mathrm{d}m_{\mathrm{c}}}{\mathrm{d}\varphi} = \frac{\mathrm{d}m_{\mathrm{c,u}}}{\mathrm{d}\varphi} + \frac{\mathrm{d}m_{\mathrm{c,i}}}{\mathrm{d}\varphi} \tag{3.46}$$

Prestrujavanje medija dešava se zbog razlike tlakova među volumenima i odvija se s mjesta višega tlaka prema mjestu nižega tlaka. Maseni protok preko usisnih ili ispušnih ventila može se izračunati iz izraza:

$$\frac{\mathrm{d}m}{\mathrm{d}\varphi} = \alpha_{\mathrm{v}} A_{\mathrm{v,geom}} \psi p_1 \sqrt{\frac{2}{R_1 T_1}} \frac{\mathrm{d}t}{\mathrm{d}\varphi}$$
(3.47)

Za podkritični omjer tlakova $1 \ge \frac{p_2}{p_1} \ge \left(\frac{2}{\kappa+1}\right)^{\frac{\kappa}{\kappa+1}}$ funkcija protjecanja ψ u izrazu (3.47) određena je prema [67]:

$$\psi = \sqrt{\frac{\kappa}{\kappa+1} \left[\left(\frac{p_2}{p_1}\right)^{\frac{2}{\kappa}} - \left(\frac{p_2}{p_1}\right)^{\frac{\kappa+1}{\kappa}} \right]}$$
(3.48)

gdje je indeks 1 stanje u volumenu ispred, a indeks 2 stanje u volumenu iza mjesta prestrujavanja. Pri nadkritičnom omjeru tlakova:

$$\frac{p_2}{p_1} < \left(\frac{2}{\kappa+1}\right)^{\frac{\kappa}{\kappa+1}} \tag{3.49}$$

prestrujavanje se odvija brzinom zvuka, a funkcija protjecanja je:

$$\psi = \left(\frac{2}{\kappa+1}\right)^{\frac{1}{\kappa-1}} \sqrt{\frac{\kappa}{\kappa+1}} \tag{3.50}$$

Umnožak koeficijenta protoka i geometrijske protočne površine daje trenutnu efektivnu protočnu površinu te se može pisati:

$$A_{\rm v,ef} = \alpha_{\rm v} \quad A_{\rm v,geom} \tag{3.51}$$

Koeficijent protoka je funkcija podizaja ventila i ovisi o izvedbi usisnog/ispušnog kanala i smještaju ventila unutar kanala. Veličina efektivne protočne površine za analizirani motor određena je iz geometrija brijegova usisnog i ispušnog ventila te preporuka iz [68]. Osjetna toplina medija koji prestrujava pribraja se ili oduzima bilanci energije u skladu sa smjerom strujanja u odnosu prema promatranom kontrolnom volumenu. Kod istrujavanja medija iz kontrolnog volumena, sastav plina, a time i pretičak zraka, ostaju nepromijenjeni. Do promjene pretička zraka u kontrolnom volumenu dolazi samo ako u njega ustrujavaju plinovi drugačijeg sastava. Promjena pretička zraka može se prikazati izrazima:

$$\frac{\mathrm{d}\lambda_{\mathrm{c}}}{\mathrm{d}\varphi} = \frac{\mathrm{d}m_{\mathrm{c}}}{\mathrm{d}\varphi} \tag{3.52}$$

$$\frac{\mathrm{d}\lambda_{\mathrm{c}}}{\mathrm{d}\varphi} = \frac{\frac{\mathrm{d}m_{\mathrm{c,i}}}{\mathrm{d}\varphi} \left(1 - \frac{m_{\mathrm{c}} m_{\mathrm{g,c,i}}}{m_{\mathrm{g,c}} m_{\mathrm{c,i}}}\right)}{L_{\mathrm{st}}m_{\mathrm{g,c}}} = \frac{\frac{\mathrm{d}m_{\mathrm{c,i}}}{\mathrm{d}\varphi} \left(1 - \frac{\lambda_{\mathrm{c}} L_{\mathrm{st}} + 1}{\lambda_{\mathrm{i}} L_{\mathrm{st}} + 1}\right)}{L_{\mathrm{st}}m_{\mathrm{g,c}}} \qquad za \qquad \frac{\mathrm{d}m_{\mathrm{c,i}}}{\mathrm{d}\varphi} > 0 \tag{3.53}$$

$$\frac{\mathrm{d}\lambda_{\mathrm{c,i}}}{\mathrm{d}\varphi} = 0 \qquad \text{za} \qquad \frac{\mathrm{d}m_{\mathrm{c,i}}}{\mathrm{d}\varphi} < 0 \tag{3.54}$$

Promjena mase trenutnog izgorjelog goriva u promatranom kontrolnom volumenu zbog dotoka medija iz spremnika i u kojemu je pretičak zraka λ_i može se prikazati sljedećom jednadžbom:

$$\frac{\mathrm{d}m_{\mathrm{g,c}}}{\mathrm{d}\varphi} = \frac{\mathrm{d}m_{\mathrm{c,i}}}{\mathrm{d}\varphi} \frac{1}{\lambda_{\mathrm{i}}L_{\mathrm{st}} + 1} \tag{3.55}$$

3.2.8 Izmjena radnog medija kod dvotaktnog motora

Model izmjene radnog medija dvotaktnog motora uvelike se razlikuje od modela izmjene radnog medija četverotaktnog motora. U literaturi se uglavnom spominju četiri karakteristična parametra za opis procesa izmjene radnog medija kod dvotaktnog motora, a to su:

- 1. stupanj dobave $\lambda_{\rm A}$,
- 2. potpunost ispiranja $\eta_{\rm S}$,
- 3. stupanj punjenja $\eta_{\rm L}$ i
- 4. stupanj čistoć
e $\beta.$

U radu [69] stupanj dobave je definiran kao omjer mase svježeg punjenja tijekom jednog procesa i mase svježeg punjenja koju je teoretski moguće smjestiti u radni prostor cilindra motora, što se može prikazati izrazom (3.56):

$$\lambda_{\rm A} = \frac{m_{\rm c,sp,pr}}{m_{\rm c,sp,teo}} = \frac{\text{masa svježeg punjenja usisanog tijekom jednog procesa}}{\text{teoretska masa punjenja u cilindru motora}}$$
(3.56)

Potpunost ispiranja, prema [70], definira se kao omjer svježeg punjenja i zaostalih plinova izgaranja, nakon završene faze izmjene radnog medija. Prema izrazu (3.57), potpunost ispiranja definirana je kao omjer mase svježeg punjenja i ukupne mase radnog medija u cilindru motora:

$$\eta_{\rm S} = \frac{m_{\rm c,sp}}{m_{\rm c,uk}} = \frac{m_{\rm c,sp}}{m_{\rm c,zr} + m_{\rm c,zpi}} = \frac{\text{trenutna masa svježeg punjenja u cilindru motora}}{\text{ukupna masa u cilindru motora}}$$
(2.57)

(3.57)

Prema Dangu i Wallaceu [71], stupanj punjenja povezuje trenutnu količinu svježeg punjenja i teoretski moguću količinu punjenja kojom bi se radni prostor cilindra mogao ispuniti što je definirano jednadžbom (3.58):

$$\eta_{\rm L} = \frac{m_{\rm c,sp}}{m_{\rm c,sp,teo}} = \frac{\text{trenutna masa svježeg punjenja u cilindru motora}}{\text{teoretska masa svježeg punjenja u ispunjenom cilindru motora}} \quad (3.58)$$

Da bi se moglo ocijeniti koliko se svježeg punjenja nalazi u cilindru motora ili koliko ga ima u ispušnom kolektoru, u [72] je uveden stupanj čistoće koji predstavlja omjer čistog punjenja i ukupne mase radnog medija u cilindru motora te usisnom ili ispušnom kolektoru (3.59).

$$\beta = \frac{m_{(c,UK,IK),sp}}{m_{(c,UK,IK),uk}} = \frac{\text{masa svježeg punjenja (u cil., usisnom kol., ispušnom kol.)}}{\text{ukupna masa (u cil., usisnom kol., ispušnom kol.)}}$$
(3.59)

3.2.8.1 Način ispiranja cilindra velikih brodskih dvotaktnih motora

Obzirom na veliki omjer stapaja prema promjeru cilindra (veći od 2,5), kod velikih dvotaktnih brodskih dizelskih motora, za ispiranje u obzir dolazi samo uzdužno ispiranje, s usisnim rasporima pri dnu cilindra i s ispušnim ventilom u glavi cilindra.

Pri uzdužnom ispiranju svježe punjenje ulazi kroz usisne raspore i potiskuje plinove izgaranja prema ispušnom ventilu. Kako bi se ispiranje poboljšalo, usisni se raspori postavljaju pod kutem od 15° obzirom na radijalni smjer. Takav položaj usisnih otvora omogućuje stabilno kružno strujanje smjese u cilindru, čime se poboljšava ispiranje zaostalih plinova izgaranja. Uz dobro ispiranje cilindra, ovakvo strujanje omogućuje i bolje miješanje goriva i svježe usisanog punjenja. Općenito, dvotaktni dizelski motori s uzdužnim ispiranjem postižu najbolji stupanj ispiranja cilindra.

3.2.8.2 Modeli izmjene radnog medija

Detaljni pregled i opis različitih modela za izmjenu radnog medija dat je u [73].

U tom radu dan je pregled i numerički modeli za tri vrste izmjene radnog medija u cilindru dvotaktnog dizelskog motora:

- 1. potpuno potiskivanje,
- 2. potpuno miješanje i
- 3. kombinirano potiskivanje i miješanje.

Model kombiniranog potiskivanja i miješanja je kombinacija osnovnih modela potpunog potiskivanja i potpunog miješanja. Niti jedan model ne uzima u obzir kinetičku energiju plina.

S druge strane, metode potpunog potiskivanja i potpunog miješanja su najjednostavnije metode za opis procesa izmjene radnog medija. Te su metode razvijene u vrijeme kada nije bilo računala te se uz pomoć jednostavnog numeričkog aparata pokušalo ocijeniti uspješnost i kvalitetu izmjene radnog medija. Detaljnija analiza ispiranja i izmjene radnog medija moguća je samo primjenom numeričke dinamike fluida (CFD).

U numeričkom modelu korištenom u ovom radu primjenjuje se metoda potpunog miješanja, pa će se u nastavku ovoj metodi posvetiti veća pozornost.

3.2.8.3 Model potpunog miješanja

Model potpunog miješanja [74] pretpostavlja ustrujavanje svježeg punjenja u cilindar i njegovo trenutno miješanje sa sadržajem koji se nalazi u cilindru. Ovdje se striktno poštuje pretpostavka homogenosti sastava u promatranom volumenu, tako da je dovedena masa svježeg punjenja isti trentak pomiješana s postojećom masom u homogenu smjesu. Plinovi koji izlaze kroz ispuh su homogena smjesa iz promatranog volumena u sastavu koji diktira proces motora. Model je izveden na temelju pretpostavke da se miješanje odvija trenutno.



Slika 3.4: Model potpunog miješanja

Novo stanje nakon trenutnog miješanja dobiva se po modelu identičnom kao i kod izmjene radnog medija za četverotaktni motor. Svježi medij koji je ušao prilikom ispiranja povećava masu i sa sobom donosi osjetnu toplinu. Smjesa koja izlazi kroz ispušni ventil sa sobom odnosi dio mase i dio osjetne topline iz cilindra. Model za numeričke simulacije rada motora, korišten u ovome radu, u sebi sadrži sve elemente potrebne za pouzdanu simulaciju ukupnog procesa ispiranja motora.

Ranije su različiti autori predlagali hibridne modele izmjene radnoga medija kod dvotaktnih motora, kako bi čim više smanjili opseg potrebnih proračuna. Na slici 3.5 prikazana je promjena potpunosti ispiranja, stupnja punjenja i stupnja čistoće plinova u ovisnosti o stupnju dobave. Također, dan je prikaz potpunosti ispiranja dobivene modelom potpunog miješanja i usporedba s potpunošću ispiranja koja je dobivena modelom potpunog potiskivanja.

Uočljivo je da model potpunog miješanja predviđa slabiju izmjenu radnog medija u odnosu na model potpunog potiskivanja. Stvarna potpunost ispiranja za suvremene brodske dvotaktne dizelske motore je vrijednost unutar raspona određenog krivuljama modela potpunog potiskivanja i potpunog miješanja, pri čemu su vrijednosti stupnja dobave u pravilu $\lambda_A < 1, 2$.



Slika 3.5: Promjena potpunosti ispiranja, odstupnja punjenja i čistoće plinova u ovisnosti o stupnju dobave

3.3 Usisni kolektor

Matematički model usisnog kolektora pretpostavlja promjenu tlaka u vremenu, koja nastaje zbog izmjene radnog medija. Izmjena radnog medija odvija se preko površina čije su veličine i zakonitosti promjene unaprijed definirane otvaranjem raspora u stijenci cilindarske košuljice. Količina radnog medija koja ustrujava ili istrujava u odabranom vremenskom koraku pridodaje se ili oduzima postojećoj masi radnog medija i izvodi se novi proračun za pretičak zraka. Jednako se promatra dotok ili otjecanje osjetne topline i njhov utjecaj na promjenu temperature. Na kraju, iz jednadžbe stanja idealnog plina na temelju dobivene nove temperature izračunava se novi tlak u promatranom kontrolnom volumenu.

Osim promjene tlaka, u obzir je uzet i prijelaz topline s radnog medija na stijenku usisnog kolektora i na stijenke usisnih kanala (ili obrnuto – prijelaz topline sa stijenki na radni medij, ovisno o razlici u temperaturama). Pomoću numeričkog modela za usisni



Slika 3.6: Usisni kolektor [2]
kolektor i njegove povezanosti s cilindrima motora, moguće je pratiti ne samo strujanje zraka iz kolektora u cilindre motora, već i eventualni povrat plinova iz cilindara, te u konačnici promjenu mase i pretička zraka koji se mogu desiti zbog te pojave:

$$\frac{\mathrm{d}\lambda_{\mathrm{UK}}}{\mathrm{d}\varphi} = \frac{\frac{\mathrm{d}m_{\mathrm{UK,c}}}{\mathrm{d}\varphi} \left(1 - \frac{\lambda_{\mathrm{UK}} L_{\mathrm{st}} + 1}{\lambda_{\mathrm{c}} L_{\mathrm{st}} + 1}\right)}{L_{\mathrm{st}} m_{\mathrm{g,UK}}} \tag{3.60}$$

$$\frac{\mathrm{d}m_{\mathrm{UK}}}{\mathrm{d}\varphi} = \frac{\mathrm{d}m_{\mathrm{UK,P}}}{\mathrm{d}\varphi} + \sum_{i} \frac{\mathrm{d}m_{\mathrm{UK,i}}}{\mathrm{d}\varphi}$$
(3.61)

Veoma bitna karakteristika usisnog kolektora, što uvelike olakšava proračun, je činjenica da je njegov volumen tokom rada motora konstantan i u njemu nema izgaranja goriva, pa se jednadžba za promjenu temperature u usisnom kolektoru može pisati kao:

$$\frac{\mathrm{d}Q_{\mathrm{g,UK}}}{\mathrm{d}\varphi} = 0 \quad , \quad \frac{\mathrm{d}V_{\mathrm{UK}}}{\mathrm{d}\varphi} = 0 \tag{3.62}$$

$$\frac{\mathrm{d}T_{\mathrm{UK}}}{\mathrm{d}\varphi} = \frac{1}{m_{\mathrm{UK}} \left(\frac{\partial u}{\partial T}\right)_{\mathrm{UK}}} \left[\frac{\mathrm{d}Q_{\mathrm{st,UK}}}{\mathrm{d}\varphi} + \sum_{i} h_{i} \frac{\mathrm{d}m_{\mathrm{UK,i}}}{\mathrm{d}\varphi} - u_{\mathrm{UK}} \frac{\mathrm{d}m_{\mathrm{UK}}}{\mathrm{d}\varphi} - m_{\mathrm{UK}} \left(\frac{\mathrm{d}u}{\mathrm{d}\lambda}\right)_{\mathrm{UK}} \frac{\mathrm{d}\lambda_{\mathrm{UK}}}{\mathrm{d}\varphi}\right]$$
(3.63)

3.3.1 Prijelaz topline u usisnom kolektoru

Model uzima u obzir prijelaz topline s radnog medija na stijenke usisnog kolektora i prijelaz topline u usisnim kanalima tijekom strujanja u cilindre motora i obrnuto. Toplina predana na taj način može se računati uz pomoć sljedećeg izraza:

$$\frac{\mathrm{d}Q_{\mathrm{st,UK}}}{\mathrm{d}\varphi} = \alpha_{\mathrm{UK}} A_{\mathrm{UK}} \left(T_{\mathrm{st,UK}} - T_{\mathrm{UK}} \right) \frac{\mathrm{d}t}{\mathrm{d}\varphi} + \alpha_{\mathrm{Ukan}} A_{\mathrm{Ukan}} \left(T_{\mathrm{st,Ukan}} - T_{\mathrm{UK}} \right) \frac{\mathrm{d}t}{\mathrm{d}\varphi}$$
(3.64)

Ukoliko kolektor ima oblik cijevi i ako je u njemu strujanje laminarno (Re < 2300), koeficijent prijelaza topline se računa prema jednadžbi iz [75]:

$$\alpha_{\rm UK} = 1,86 \frac{\lambda_{\rm UK}}{d_{\rm UK}} \left[{\rm Re}_{\rm UK} {\rm Pr}_{\rm UK} \frac{d_{\rm UK}}{L_{\rm UK}} \right]^{0,33}$$
(3.65)

Ako je strujanje turbulentno, tada se koeficijent prijelaza topline računa po jednadžbi:

$$\alpha_{\rm UK} = 0,024 \frac{\lambda_{\rm UK}}{d_{\rm UK}} \left[1 + \left(\frac{d_{\rm UK}}{L_{\rm UK}} \right)^{0,66} \right] {\rm Re}^{0,786} {\rm Pr}^{0,45}$$
(3.66)

Za usisni kolektor Prandtlov broj se uzima konstantnim i iznosi Pr $\approx 0,71,$ što vrijedi u cijelom rasponu temperatura od 20°C do 1500 °C.

Reynoldsov se broj određuje pomoću izraza:

$$Re = \frac{4 \, \dot{m}_{\rm UK}}{\pi \, d_{\rm UK} \, \eta_{\rm UK}} \tag{3.67}$$

Prema [60], toplinska vodljivost i dinamička viskoznost zraka izračunavaju se iz predloženih korelacija:

$$\lambda_{\rm UK} = 3,17 \cdot 10^{-4} T_{\rm UK}^{0,772} \tag{3.68}$$

$$\eta_{\rm UK} = 0,612 \cdot 10^{-6} T_{\rm UK}^{0,609} \tag{3.69}$$

Za izračun koeficijenta prijelaza topline u usisnom kanalu, može se koristiti, također prema [60] sljedeći izraz:

$$\alpha_{\text{Ukan}} = 0,277 \left(1 - 0,765 \frac{h_{\text{UV}}}{d_{\text{UV}}} \right) \ d_{\text{sr},\text{Ukan}}^{-1,675} \ T_{\text{UK}}^{0,362} \ \left(\frac{\mathrm{d}m_{\text{Ukan}}}{\mathrm{d}t} \right)^{0,675}$$
(3.70)

3.3.2 Hladnjak zraka

Puhalo komprimira zrak na viši tlak i kao kod svake kompresije, neželjena pojava je zagrijavanje medija koji se komprimira. Temperatura zraka na ulazu u hladnjak definirana je jednadžbom:

$$T'_{\rm zr} = T_{\rm atm} + \frac{T_{\rm atm}}{\eta_{\rm P}} \left(\pi_{\rm P}^{\frac{\kappa-1}{\kappa}} - 1 \right)$$
(3.71)

Hladnjak zraka uobičajeno ima vrlo tanke stijenke, pa se može zanemariti toplinska inercija u odzivu hladnjaka na promjenu temperature medija koji struji kroz njega. U numeričkoj simulaciji korišteni su izrazi za stacionarne karakteristike hladnjaka zraka. Uz poznatu površinu za prijelaz topline $A_{\rm HZ}$ i koeficijent prolaza topline $k_{\rm HZ}$, temperatura zraka nakon prolaska kroz hladnjak može se izračunati iz:

$$T_{\rm zr}^{''} = T_{\rm zr}^{'} - \left(T_{\rm zr}^{'} - T_{\rm RV}^{'}\right) \frac{1 - \exp\left[\left(\frac{W_{\rm zr}}{W_{\rm RV}} - 1\right)\frac{(A\,k)_{\rm HZ}}{W_{\rm zr}}\right]}{1 - \frac{W_{\rm zr}}{W_{\rm RV}}\exp\left[\left(\frac{W_{\rm zr}}{W_{\rm RV}} - 1\right)\frac{(A\,k)_{\rm HZ}}{W_{\rm zr}}\right]}$$
(3.72)

U (3.72) stanje radnog medija (zraka) označeno s ' odnosi se na stanje prije hladnjaka, a stanje nakon hladnjaka označeno je s ''. Slika 3.7 prikazuje dijagram bezdimenzijske promjene temperature zraka za jedan unakrsni izmjenjivač topline. Toplinski kapaciteti struja zraka i rashladne vode označeni su s $W_{\rm zr}$ i $W_{\rm RV}$, a predstavljaju produkt masenog protoka \dot{m} i specifičnog toplinskog kapaciteta c medija koji se promatra.

Toplina koja se u hladnjaku predaje sa zraka na rashladnu vodu, može se definirati slijedećim izrazom:

$$\frac{\mathrm{d}Q_{\mathrm{HZ}}}{\mathrm{d}\varphi} = W_{\mathrm{zr}} \left(t'_{\mathrm{zr}} - t'_{\mathrm{zr}} \right) \frac{1}{6n_{\mathrm{M}}}$$
(3.73)

Zbog strujanja zraka kroz hladnjak dolazi do pada tlaka, koji iznosi:

$$p'_{\rm zr} = p'_{\rm zr} - \Delta p_0 \left(\frac{\mathrm{d}m_{\rm P}}{\mathrm{d}t}\frac{\mathrm{d}t}{\mathrm{d}m_{\rm P,0}}\right)^2 \tag{3.74}$$



Slika 3.7: Bezdimenzijska promjena temperature zraka za unakrsni izmjenjivač topline

3.4 Ispušni kolektor

Nakon što u cilindru motora završe procesi izgaranja i ekspanzije plinova izgaranja, dolazi do otvaranja ispušnog ventila pri čemu produkti izgaranja prestrujavaju u ispušni kolektor. Prilikom procesa prestrujavanja plinova izgaranja dolazi do pulzacija tlaka, koje imaju veliki utjecaj na rad turbine i turbopuhala u cijelosti. Isto tako, ova pojava ima veliki utjecaj na ponašanje motora u prijelaznim (tranzijentnim) režimima rada. Proces u ispušnom kolektoru simuliran je pomoću kvazistacionarnog modela, uz postavljene diferencijalne jednadžbe očuvanja mase i energije, te poštivajući odgovarajuće rubne uvjete, prikazane na Slici 3.8. Kao i za usisni, tako i za ispušni kolektor vrijede činjenice da u



Slika 3.8: Ispušni kolektor [2]

njemu nema izgaranja goriva i nema promjene volumena samog kolektora, pa jednadžba za promjenu temperature u ovisnosti o kutu koljena koljenastog vratila glasi:

$$\frac{\mathrm{d}T_{\mathrm{IK}}}{\mathrm{d}\varphi} = \frac{1}{m_{\mathrm{IK}} \left(\frac{\partial u}{\partial T}\right)_{\mathrm{IK}}} \left[\frac{\mathrm{d}Q_{\mathrm{st,IK}}}{\mathrm{d}\varphi} + \sum_{i} h_{i} \frac{\mathrm{d}m_{\mathrm{IK,i}}}{\mathrm{d}\varphi} - u_{\mathrm{IK}} \frac{\mathrm{d}m_{\mathrm{IK}}}{\mathrm{d}\varphi} - m_{\mathrm{IK}} \left(\frac{\mathrm{d}u}{\mathrm{d}\lambda}\right)_{\mathrm{IK}} \frac{\mathrm{d}\lambda_{\mathrm{IK}}}{\mathrm{d}\varphi} \right]$$
(3.75)

Tijekom prestrujavanja produkata izgaranja iz cilindra motora u ispušni kolektor pretpostavljeno je trenutno i potpuno miješanje s plinovima u kontrolnom volumenu ispušnog kolektora, te se promjena pretička zraka prema kutu koljena koljenastog vratila može opisati jednadžbom(3.76), ali jednadžba vrijedi samo u slučaju kada je d $m_{\rm IK,i}/d\varphi > 0$:

$$\frac{\mathrm{d}\lambda_{\mathrm{IK}}}{\mathrm{d}\varphi} = \frac{\sum_{i}^{i} \frac{\mathrm{d}m_{\mathrm{IK},i}}{\mathrm{d}\varphi} \left(1 - \frac{\lambda_{\mathrm{IK}} L_{\mathrm{st}} + 1}{\lambda_{i} L_{\mathrm{st}} + 1}\right)}{L_{\mathrm{st}} m_{\mathrm{g,IK}}}$$
(3.76)

Promjena mase u ispušnom kolektoru dobiva se iz bilance masa koje ulaze ili izlaze iz ispušnog kolektora:

$$\frac{\mathrm{d}m_{\mathrm{IK}}}{\mathrm{d}\varphi} = \frac{\mathrm{d}m_{\mathrm{IK,T}}}{\mathrm{d}\varphi} + \sum_{i} \frac{\mathrm{d}m_{\mathrm{IK},i}}{\mathrm{d}\varphi}$$
(3.77)

3.4.1 Prijelaz topline u ispušnom kolektoru

Ispušni plinovi koji izlaze iz cilindara motora i ulaze u ispušni kolektor imaju visoku temperaturu, pa je prijelaz topline s radnog medija na stijenke ispušnog kolektora vrlo intenzivan. U numeričkom modelu prijelaza topline u obzir je uzeta i toplina koja je predana u ispušnim kanalima koji spajaju cilindarsku glavu i ispušni kolektor. Jednadžba za prijenos topline u ovisnosti o kutu koljena koljenastog vratila glasi:

$$\frac{\mathrm{d}Q_{\mathrm{st,IK}}}{\mathrm{d}\varphi} = \alpha_{\mathrm{IK}} A_{\mathrm{IK}} \left(T_{\mathrm{st,IK}} - T_{\mathrm{IK}} \right) \frac{\mathrm{d}t}{\mathrm{d}\varphi} + \alpha_{\mathrm{Ikan}} A_{\mathrm{Ikan}} \left(T_{\mathrm{st,Ikan}} - T_{\mathrm{IK}} \right) \frac{\mathrm{d}t}{\mathrm{d}\varphi}$$
(3.78)

Ovisno o tome da li je riječ o laminarnom ili turbulentnom strujanju, koeficijenti prijelaza topline prema stijenci ispušnog kolektora izračunavaju se prema izrazima (3.65) ili (3.66). U spomenute je izraze potrebno uvrstiti toplinsku vodljivost i dinamičku viskoznost ispušnih plinova, koji se prema [60] mogu izračunati iz jednadžbi:

$$\lambda_{\rm IK} = 2,02 \cdot 10^{-4} \ T_{\rm IK}^{0,837} \tag{3.79}$$

$$\eta_{\rm IK} = 0,355 \cdot 10^{-6} T_{\rm IK}^{0,679} \tag{3.80}$$

Koeficijent prijelaza topline u ispušnim kanalima izračunava se prema sljedećem izrazu:

$$\alpha_{\rm Ikan} = 3,27 \left(1 - 0,797 \frac{h_{\rm IV}}{d_{\rm IV}} \right) \ d_{\rm sr,Ikan}^{-1,5} \ T_{\rm IK}^{0,517} \left(\frac{\mathrm{d}m_{\rm Ikan}}{\mathrm{d}t} \right)^{0,5}$$
(3.81)

3.5 Turbopuhalo

Numerički model turbopuhala sastoji se od 2 dijela – od modela turbine na ispušne plinove i modela puhala. Uravnoteženjem momenta dobivenog od turbine i momenta potrebnog za rad puhala, uključujući sve gubitke, izračunava se brzina vrtnje i radna točka turbopuhala. Slika 3.9 prikazuje fizikalne veličine koje određuju rad turbopuhala.

Turbina i puhalo vezani su krutom vezom (vratilom) što je prikazano dodatnom jednadžbom dinamike turbopuhala, koja omogućuje izračun promjene brzine vrtnje rotora turbopuhala na temelju razlike momenata puhala i turbine te momenta tromosti rotora turbopuhala.



Slika 3.9: Turbopuhalo

3.5.1 Turbina na ispušne plinove

Maseni protok kroz turbinu određuje se s pomoću jednadžbe:

$$\frac{\mathrm{d}m_{\mathrm{T}}}{\mathrm{d}\varphi} = \alpha_{\mathrm{T}} A_{\mathrm{T,geom}} \psi p_{\mathrm{IK}} \sqrt{\frac{2}{R_{\mathrm{IK}}T_{\mathrm{IK}}}} \frac{\mathrm{d}t}{\mathrm{d}\varphi}$$
(3.82)

gdje je $\alpha_{\rm T}$ koeficijent protoka, $A_{\rm T,geom}$ geometrijski protočni presjek turbine, a ψ funkcija protoka.

Adijabatski stupanj djelovanja turbine $\eta_{\rm T}$ jest omjer stvarnog i adijabatskog pada entalpije u turbini:

$$\eta_{\rm T} = \frac{\Delta h_{\rm T}}{\Delta h_{\rm s,T}} \tag{3.83}$$

gdje je $\Delta h_{\rm T}$ je stvarni pad entalpije pri ekspanziji u turbini od stanja na ulazu do stanja na izlazu iz turbine.

Adijabatski pad entalpije definiran je jednadžbom:

$$\Delta h_{\rm s,T} = \frac{\kappa_{\rm IK}}{\kappa_{\rm IK} - 1} R_{\rm IK} T_{\rm IK} \left[1 - \left(\frac{1}{\pi_{\rm T}}\right)^{\frac{\kappa_{\rm IK} - 1}{\kappa_{\rm IK}}} \right]$$
(3.84)

s tim da je $\pi_{\rm T}$ određen omjerom tlakova na ulaznoj i izlaznoj prirubnici turbine. Tlak na izlaznoj prirubnici određen je tlakom okoline uvećanim za pad tlaka u cjevovodu ispušnog sustava.

Omjer obodne brzine rotora $u_{\rm T}$ i brzine strujanja c_0 , koja odgovara adijabatskom padu entalpije, je bezdimenzijska značajka brzine ν :

$$\nu = \frac{u_{\rm T}}{c_0} = \frac{u_{\rm T}}{\sqrt{2\ \Delta h_{\rm s,T}}} \tag{3.85}$$

Eksperimentalnim mjerenjima na različitim turbinama utvrđeno je da su koeficijent protoka $\alpha_{\rm T}$ i maksimalni adijabatski stupanj djelovanja $\eta_{\rm T,max}$ funkcije omjera tlakova $\pi_{\rm T}$, bezdimenzijske značajke brzine ν i geometrije turbine, te se mogu prikazati dijagramom. Dva takva dijagrama prikazana su na slici 3.10 i na slici 3.11 ([76]).

Oblik krivulje $\eta_{\rm T}/\eta_{\rm T,max}$ ovisi o izvedbi lopatica i neznatno se mijenja za različite omjere tlakova $\pi_{\rm T}$. Krivulja promjene stupnja djelovanja turbine može se prikazati pomoću polinoma drugog stupnja. U slučajevima kada cijela funkcija nije parabola, vrh funkcije može se aproksimirati parabolom, a nastavci tangentama. Faktor protoka $\alpha_{\rm T}$ prikazuje se kao izlomljena i linearna funkcija bezdimenzijske značajke vrtnje za određenu vrijednost omjera tlakova $\pi_{\rm T}$.



Slika 3.10: Polje karakteristika radijalne turbine na ispušne plinove



Slika 3.11: Polje karakteristika aksijalne turbine na ispušne plinove

3.5.2 Puhalo

Numerički model puhala baziran je na određivanju protoka zraka i stupnja djelovanja puhala u zavisnosti od tlaka prednabijanja, brzine vrtnje puhala i stanja okoline. Za pojedino promatrano puhalo ti se parametri mogu odrediti iz polja karakteristika puhala, kao na Slici 3.12, koje su svedene na standardnu temperaturu $T_0 = 288$ K i za koje vrijedi:

$$\pi_{\rm P} = f\left(\frac{\mathrm{d}V_{288}}{\mathrm{d}t}, n_{\rm TP,288}\right) \tag{3.86}$$

$$\eta_{\rm P} = f\left(\frac{\mathrm{d}V_{288}}{\mathrm{d}t}, n_{\rm TP,288}\right) = \frac{\Delta h_{\rm s,P}}{\Delta h_{\rm P}} \tag{3.87}$$



Slika 3.12: Polje karakteristika puhala

Maseni protok kroz puhalo određen je jednadžbom:

$$\frac{\mathrm{d}m_{\mathrm{P}}}{\mathrm{d}\varphi} = \frac{\mathrm{d}V_{288}}{\mathrm{d}t} \sqrt{\frac{T_0}{T_{\mathrm{atm}}}} \frac{p_{\mathrm{atm}}}{R_{\mathrm{atm}}} \frac{\mathrm{d}t}{\mathrm{d}\varphi}$$
(3.88)

a korigirani volumni protok i broj okretaja dobivaju se iz:

$$\frac{\mathrm{d}\,V_{288}}{\mathrm{d}t} = \sqrt{\frac{T_0}{T_{\mathrm{atm}}}} \frac{\mathrm{d}\,V_{\mathrm{zr}}}{\mathrm{d}t} \tag{3.89}$$

$$n_{\rm TP,288} = n_{\rm TP} \sqrt{\frac{T_0}{T_{\rm atm}}} \tag{3.90}$$

Rad potreban za pogon puhala tijekom jednog koraka proračuna je:

$$W_{\rm P} = \int \frac{\mathrm{d}m_{\rm P}}{\mathrm{d}\varphi} \frac{\Delta h_{\rm s,P}}{\eta_{\rm s,P} \eta_{\rm meh} \eta_{\rm vol}} \mathrm{d}\varphi$$
(3.91)

Opis polja karakteristika puhala ima značajan utjecaj na simulaciju procesa u motoru, pa je tom problemu posvećena posebna pozornost. Polje karakteristika puhala prikazuje se funkcijama $\pi_{\rm P} = f\left(\dot{V}, n\right)$ i $\eta_{\rm P} = f\left(\dot{V}, n\right)$, te je takav pristup preuzet iz [77]. Funkcije $\pi_{\rm P} = f\left(\dot{V}\right)$ i $\eta_{\rm P} = f\left(\dot{V}\right)$ mogu se opisati regresijskim polinomima 4. ili 5. reda za konstantnu brzinu vrtnje. Brzina vrtnje turbopuhala i stupanj djelovanja puhala određuju se iz početnih vrijednosti za π i \dot{V} interpolacijom u polju karakteristika. Za prikaz omjera tlakova π koristi se regresijski polinom sljedećeg oblika:

$$\pi_{\rm P} = \frac{1}{B_0 + \sum_{i=1}^5 (B_i \ n_{\rm TP}^i) + \sum_{j=1}^5 (C_j \ n_{\rm TP}^j \ \dot{V}^{D_1})} + \frac{n_{\rm TP}^2}{D_2}$$
(3.92)

gdje su B_0 do B_5 , C_1 do C_5 te D_1 i D_2 koeficijenti koji se određuju regresijskom metodom najmanjih kvadrata. Na temelju poznatog omjera tlakova i protoka, stupanj djelovanja puhala prikazan je regresijskim polinomom:

$$\eta_{\rm P} = \sum_{i=0}^{2} A_i \ \pi_{\rm P}^i + \dot{V}^2 \sum_{i=0}^{2} B_i \ \pi_{\rm P}^i + (\pi_{\rm P} - 1)^{2K} \ \sum_{i=0}^{2} C_i \ \pi_{\rm P}^i + (\pi_{\rm P} - 1)^K \ \sum_{i=0}^{2} D_i \ \pi_{\rm P}^i \qquad (3.93)$$

gdje se koeficijenti A_i, B_i, C_i, D_i i K određuju na jednak način kao u izrazu (3.92).

Ovaj pristup zahtjeva vrlo opsežnu pripremu podataka. Prednost mu je u minimalnom zauzimanju memorije računala. Izračun koeficijenata polinoma izveden je s pomoću zasebnog računalnog programa koji je razvijen prilikom izrade rada [77].

3.5.3 Dinamika turbopuhala

Rotor turbopuhala sastoji se od rotora puhala i rotora turbine na ispušne plinove, koji su međusobno povezani vratilom. Zajedničko vratilo osigurava krutu vezu između puhala i turbine, što znači jednak broj okretaja i prijenos zakretnog momenta. Razlika između zakretnog momenta ostvarenog na turbini na ispušne plinove i zakretnog momenta potrebnog za pogon puhala ubrzava ili usporava rotor turbopuhala. Osim o veličini razlike zakretnih momenata, prirast brzine vrtnje rotora ovisi i o momentu tromosti rotora turbopuhala:

$$\frac{\mathrm{d}n_{\mathrm{TP}}}{\mathrm{d}t} = \frac{M_{\mathrm{T}} - M_{\mathrm{P}}}{J_{\mathrm{TP}}} \frac{1}{2\pi} \frac{\mathrm{d}t}{\mathrm{d}\varphi} = \frac{M_{\mathrm{T}} - M_{\mathrm{P}}}{J_{\mathrm{TP}}} \frac{1}{120 \ n_{\mathrm{M}} \ \pi}$$
(3.94)

Momenti turbine i puhala određuju se iz rada turbine i puhala:

$$M_{\rm T} = \frac{\mathrm{d} W_{\rm T}}{\mathrm{d} t} \quad \frac{1}{2 \pi n_{\rm TP}} = \frac{\mathrm{d} m_{\rm T}}{\mathrm{d} \varphi} \ \Delta h_{\rm s,T} \ \eta_{\rm T} \ \frac{1}{2 \pi n_{\rm TP}} \quad \frac{\mathrm{d} \varphi}{\mathrm{d} t} \tag{3.95}$$

$$M_{\rm P} = \frac{\mathrm{d} W_{\rm P}}{\mathrm{d} t} \quad \frac{1}{2 \pi n_{\rm TP}} = \frac{\mathrm{d} m_{\rm P}}{\mathrm{d} \varphi} \quad \frac{\Delta h_{\rm s,P}}{\eta_{\rm P} \eta_{\rm meh} \eta_{\rm vol}} \quad \frac{1}{2 \pi n_{\rm TP}} \quad \frac{\mathrm{d} \varphi}{\mathrm{d} t} \tag{3.96}$$

3.6 Dinamika motornog mehanizma

Modeliranje nestacionarnog rada motora, odnosno promjena brzine vrtnje koljenastog vratila, može se provesti pomoću ekvivalentnog dinamičkog sistema. U ovom slučaju, zanemaruje se kinetička energija razvodnog mehanizma i elemenata visokotlačne pumpe te elastične deformacije motornog mehanizma. Promjena brzine vrtnje koljenastog vratila može se opisati sljedećim jednadžbama:

$$(J_{\rm M} + J_{\rm Pot}) \frac{\mathrm{d}\omega_{\rm M}}{\mathrm{d}t} = M_{\rm M} + M_{\rm Pot}$$
(3.97)

gdje su $J_{\rm M}$ i $J_{\rm Pot}$ momenti tromosti motora i potrošača.

Promjena brzine vrtnje dizelskog motora može se prikazati jednadžbom:

$$\frac{\mathrm{d}n_{\mathrm{M}}}{\mathrm{d}t} = \frac{M_{\mathrm{M}} + M_{\mathrm{Pot}}}{J_{\mathrm{M}} + J_{\mathrm{Pot}}} \frac{1}{2\pi} \frac{\mathrm{d}t}{\mathrm{d}\varphi}$$
(3.98)

Prilikom izračuna promjene brzine vrtnje, u modelu dizelskog motora korištene su efektivna snaga motora $P_{\rm M}$ i snaga koju apsorbira potrošač $P_{\rm Pot}$ pa se izraz (3.98) može predefinirati u oblik:

$$\frac{\mathrm{d}n_{\mathrm{M}}}{\mathrm{d}\varphi} = \frac{P_{\mathrm{M}} + P_{\mathrm{Pot}}}{J_{\mathrm{M}} + J_{\mathrm{Pot}}} \left(\frac{1}{2\pi}\right)^2 \frac{1}{n_{\mathrm{M}}} \frac{\mathrm{d}t}{\mathrm{d}\varphi} = \frac{P_{\mathrm{M}} + P_{\mathrm{Pot}}}{360 \ n_{\mathrm{M}}^2 \ (J_{\mathrm{M}} + J_{\mathrm{Pot}})} \left(\frac{1}{2\pi}\right)^2 \tag{3.99}$$

Iz poznatog rada procesa u cilindru motora izračunava se indicirana snaga motora:

$$P_{\rm ind} = \frac{2 n_{\rm M} z}{\tau} \int \frac{\mathrm{d} W_{\rm c}}{\mathrm{d} \varphi} \,\mathrm{d} \varphi \tag{3.100}$$

Indicirana snaga motora može se izračunati i iz srednjeg indiciranog tlaka procesa $p_{\rm sr,ind}$:

$$P_{\rm ind} = \frac{2 n_{\rm M} z}{\tau} \quad V_{\rm s} \, p_{\rm sr,ind} \tag{3.101}$$

U toku gibanja motornog mehanizma javljaju se gubici zbog trenja i pokretanja pomoćne opreme motora kao što su bregasto vratilo, ventili, visokotlačna pumpa goriva, pumpa ulja i rashladne vode i sl. Iz tih razloga je efektivna snaga motora $P_{\rm M}$ koju motor predaje na izlaznoj spojci potrošaču, manja od indicirane snage $P_{\rm ind}$ upravo za vrijednost navedenih gubitaka. Efektivna snaga motora može se izraziti preko srednjega efektivnog tlaka $p_{\rm sr,ef}$, koji se dobije na način da se od indiciranog tlaka $p_{\rm ind}$ oduzme srednji tlak gubitaka trenja i pogona pomoćne opreme $p_{\rm sr,tr}$:

$$P_{\rm M} = \frac{2n_{\rm M}z}{\tau} V_{\rm s} \ p_{\rm sr,ef} = P_{\rm ind} \frac{p_{\rm sr,ef}}{p_{\rm sr,ind}}$$
(3.102)

$$p_{\rm sr,ef} = p_{\rm sr,ind} - p_{\rm sr,tr} \tag{3.103}$$

Srednji tlak gubitaka trenja $p_{\rm sr,tr}$ prikazuje se kao zbroj tlakova raznih gubitaka koji se javljaju pri radu motora. Pregled svih gubitaka koji zbrojno čine srednji tlak gubitaka trenja $p_{\rm sr,tr}$ prikazan je u nastavku.

Utjecaj trenja u motornom mehanizmu te mehanizmima za pogon ventila i visokotlačne pumpe za ubrizgavanje goriva opisan je jednadžbom:

$$\Delta p_{\rm tr,1} = 6,7 d_{\rm c}^{-0,329} - 89 d_{\rm c}^{-0,943} \left[1 - \left(\frac{n}{n_0}\right)^2 \right] \qquad \text{bar} \tag{3.104}$$

gdje je $d_{\rm c}$ promjer cilindra u mm.

Utjecaj opterećenja motora s izravnim ubrizgavanjem definira se kao:

$$\Delta p_{\rm tr,2} = 0,0002 \ p_{\rm sr,ef}^3 - 0,006 \ p_{\rm sr,ef} \qquad \text{bar} \tag{3.105}$$

Tlak prednabijanja ima važan utjecaj na tlak trenja, što se prikazuje izrazom:

$$\Delta p_{\rm tr,3} = \left(\frac{p_{\rm UK}}{p_{\rm atm}} - 1\right) \sqrt{0,1874 - 0,018} \ c_{\rm m} \qquad \text{bar} \tag{3.106}$$

29

Ukoliko temperatura ulja za podmazivanje ili temperatura rashladne vode odstupaju od nazivnih, onda se taj utjecaj može prikazati sljedećim izrazima:

$$\Delta p_{\rm tr,4} = -0,005 \ \left(T_{\rm ulja} - T_{\rm ulja,0}\right)$$
 bar (3.107)

$$\Delta p_{\rm tr,5} = -0,0055 \quad (T_{\rm RV} - T_{\rm RV,0}) \qquad \text{bar} \tag{3.108}$$

Na kraju, ukupni srednji tlak gubitaka trenja je zbroj navedenih tlakova gubitaka:

$$p_{\rm sr,tr} = \Delta p_{\rm tr,1} + \Delta p_{\rm tr,2} + \Delta p_{\rm tr,3} + \Delta p_{\rm tr,4} + \Delta p_{\rm tr,5}$$
(3.109)

3.7 Regulator

U stvarnim radnim uvjetima, opterećenje motora nije konstantno već se neprestano mijenja. Ako bi dobava goriva u cilindar motora bila konstanta, brzina vrtnje motora bi se mijenjala obrnuto proporcionalno promjeni opterećenja. Uređaj koji prati promjenu brzine vrtnje motora i upravlja pomakom poluge za regulaciju dobave goriva je upravo regulator. Upravljajući pomakom poluge za regulaciju dobave goriva, regulator uspostavlja i održava željenu brzinu vrtnje. Regulator također omogućuje i promjenu željene brzine vrtnje kako bi se motor mogao dovesti u neku novu radnu točku. Prema načinu rada, tj. prema njihovom djelovanju, regulatori se dijele na:

- 1. Regulatore s proporcionalnim djelovanjem (P),
- 2. Regulatore s integracijskim djelovanjem (I),
- 3. Regulatore s derivacijskim djelovanjem (D),
- 4. Regulatore s kombinacijom gornja tri djelovanja.

Kako bi se uočile razlike između različitih tipova djelovanja, potrebno je definirati sustav u kojem se odvija regulacija, reguliranu veličinu, regulator i postavni član. Na primjeru dizelskog motora, sustav u kojem se odvija regulacija je motor sa svim značajkama i vanjskim utjecajima, regulirana veličina je brzina vrtnje motora, regulator djeluje po određenom principu djelovanja, a postavni član predstavlja pomak ručice za dobavu goriva visokotlačne pumpe.

Jednostavni proporcionalni regulator djeluje proporcionalno pogrešci e, odnosno proporcionalno odstupanju od postavljenog broja okretaja. Na temelju očitane pogreške i faktora proporcionalnosti $K_{\rm p}$ određuje se nova vrijednost postavnog člana y, što će utjecati na ispravljanje regulirane veličine prema željenoj vrijednosti. Jednadžba P-regulatora glasi:

$$y(t) = K_{\rm p} e(t)$$
 (3.110)

Nedostatak proporcionalnog regulatora vidljiv je u nemogućnosti otklanjanja trajnog odstupanja regulirane veličine od postavljene vrijednosti. Dodavanjem integracijskog djelovanja dobiva se PI-regulator koji trajno otklanja pogrešku regulirane veličine:

$$y(t) = K_{\rm p}\left(e(t) + \frac{\int e(t) \, \mathrm{d}t}{T_{\rm I}}\right)$$
(3.111)

gdje je $T_{\rm I}$ vrijeme unutar kojega se poništava odstupanje regulirane veličine od postavljene veličine.

Pri regulaciji brzine vrtnje dizelskog motora PI-regulator održava konstantnu brzinu vrtnje bez odstupanja od postavljene vrijednosti i bez obzira na veličinu trenutnog opterećenja. No, ako dizelski motor služi za pokretanje generatora električne energije, PIregulator najčešće ne može udovoljiti zahtjevima regulacije takvog sistema. Pri naglom porastu opterećenja PI-regulator započinje djelovati tek nakon što je došlo do promjene brzine vrtnje, što može dovesti do zakašnjele reakcije regulatora i nedopuštenog pada brzine vrtnje. Taj se nedostatak može riješiti dodavanjem derivacijskog djelovanja, čime se dobiva PID-regulator prikazan izrazom (3.112)

$$y(t) = K_{\rm p}\left(e(t) + \frac{\int e(t) \, \mathrm{d}t}{T_{\rm I}} + T_{\rm D}\frac{\mathrm{d}e(t)}{\mathrm{d}t}\right)$$
(3.112)

gdje je $T_{\rm D}$ vremenska konstanta koja karakterizira intenzitet derivacijske komponente pri djelovanju regulatora.

Zahvaljujući derivacijskom djelovanju, PID-regulator reagira već na gradijent promjene brzine vrtnje ili kod pogona generatora električne energije reagira već na gradijent porasta opterećenja na sabirnicama generatora. Derivacijsko djelovanje reagira samo na brzinu promjene odstupanja u vremenu, a ne uzima u obzir veličinu odstupanja. Integracijsko djelovanje djeluje sporo i oscilirajuće, odnosno destabilizirajuće ako se promatra odvojeno. Regulatori s integracijskim i derivacijskim djelovanjem u praksi se nikada ne rabe samostalno, već se kombiniraju s proporcionalnim regulatorom u PI ili PD regulatore. PID regulator objedinjuje dobre karakteristike svih triju djelovanja te se povoljnim odabirom konstanti regulatora može postići željeno ponašanje reguliranog sustava.

Regulatori za dizelske motore mogu biti mehanički, hidraulički ili digitalni regulatori s hidrauličkim, elektromagnetskim ili elektromotornim aktuatorima. Ako je regulator mehanički, onda se opisuje sljedećom jednadžbom:

$$\frac{m_{\rm R}}{c_{\rm R}}\frac{{\rm d}^2 x_{\rm R}}{{\rm d}t^2} + \frac{d_{\rm R}}{c_{\rm R}}\frac{{\rm d}x_{\rm R}}{{\rm d}t} + \frac{F_{\rm tr}}{c_{\rm R}}\operatorname{sign}\left(\frac{{\rm d}x_{\rm R}}{{\rm d}t}\right) + x_{\rm R} = K_{\rm p}\left(n_{\rm R} + \frac{1}{T_{\rm I}}\int n_{\rm R} \,\,{\rm d}t + T_{\rm D}\frac{{\rm d}}{{\rm d}t}n_{\rm R}\right) \quad (3.113)$$

gdje su:

- $m_{\rm R}~$ slobodne mase regulatora,
- $d_{\rm R}$ prigušenje regulatora,
- $c_{\rm R}$ krutost opruge regulatora,
- $F_{\rm tr}$ Coulombovo trenje,
- $x_{\rm R}$ hod ručice za dobavu goriva i
- $n_{\rm R}$ brzina vrtnje motora.

3.8 Visokotlačna pumpa goriva

Kod sporohodnih brodskih motora gorivo se ubrizgava u cilindar pod visokim tlakom (600 – 1600 bar), što ovisi o tipu motora i o izvedbi sustava za ubrizgavanje goriva. U numeričkoj simulaciji korištena je visokotlačna pumpa sa spiralno izvedenim rubom, kod koje se količina goriva definira zakretanjem klipa. Zakretanjem klipa upravlja regulator preko poluge goriva. Kod definiranja i odabira pumpe goriva za primjenu na brodu, treba uzeti u obzir činjenicu kako se brodsko gorivo ukrcava na različitim mjestima, pa

su i svojstva goriva, kao i njegova kvaliteta različiti. Stoga, kako bi se poboljšao proces izgaranja i prilagodio različitim kvalitetama goriva, u sistem pumpe goriva dodan je zasebni sustav koji omogućava promjenu trenutka početka ubrizgavanja - VIT (Variable Injection Timing). Visokotlačna pumpa s takvim sustavom, koji se primjenjuje na MAN B&W sporohodnim brodskim motorima prikazana je na slici 3.13



Slika 3.13: Visokotlačna pumpa goriva s VIT sustavom sporohodnog brodskog motora [78]

Trenutak početka ubrizgavanja određuje regulator pomicanjem poluge VIT sustava, čime se po visini pomiče kućište pumpe na kojem je preljevni ventil. Prema poziciji preljevnog ventila određuje se početak dobave. Dobava će započeti nakon što klip pumpe zatvori preljevni ventil. Prema izvještajima proizvođača, primjenom VIT sustava smanjuje se potrošnja goriva za 5,5 do 6,5 g/kWh pri 90 % maksimalnog trajnog opterećenja.

Korištenjem VIT sustava moguće je početak ubrizgavanja mijenjati na ranije ili kasnije u odnosu na standardni. Prilikom ranijeg početka ubrizgavanja maksimalni tlak se postiže kod 85% maksimalnog trajnog opterećenja. Nakon 85% opterećenja sustav postavlja kasnije ubrizgavanje, kako bi se održavao konstantan tlak izgaranja sve do 100% maksimalnog trajnog opterećenja. Signal VIT sustava jednak je nuli za opterećenje manje od 40%, kako bi se izbjegle česte promjene prilikom manevriranja. Djelovanje visokotlačne pumpe goriva s VIT funkcijom prikazano je na slici 3.14.

Količina goriva koja se ubrizgava u cilindar motora ovisi o položaju ručice za dobavu goriva i o brzini vrtnje motora. Polje značajki pumpe goriva, dobiveno eksperimentalnim ispitivanjem visokotlačnih pumpi, prikazano je na slici 3.15.

U stvarnim uvjetima, pumpa ubrizgava gorivo u cilindar u kojem se nalazi stlačeni radni medij, a ta je količina goriva manja od količine izmjerene na ispitnom stolu. Zbog toga je nužno u polje karakteristika pumpe goriva (Slika 3.15) uvesti određeni faktor korekcije. Predloženi korekcijski faktor dobave za polje karakteristika visokotlačne pumpe goriva u radu [79] iznosi 0,8. U [80] prikazan je matematički model procesa ubrizgavanja koji koristi jednadžbe dinamike mehaničkih dijelova visokotlačne pumpe i jednadžbe nestacionarnog strujanja nekompresibilnog fluida.



Slika 3.14: Djelovanje visokotlačne pumpe goriva s VIT funkcijom



Slika 3.15: Općenite karakteristike visokotlačne pumpe goriva

3.9 Sustav dizelskog motora

U radu su do sada prikazani matematički modeli svih komponenti brodskog dizelskog motora s prednabijanjem. Povezivanjem tih komponenti vezama za prijenos mase i energije, simuliraju se procesi u ukupnom motoru i njegove karakteristike za različite izvedbe i uvjete rada. Pri međudjelovanju vezama spojenih komponenti treba uzeti u obzir činjenicu da svaka veza ima svoje specifične značajke. Slika 3.16 prikazuje dijagram toka informacija za model brodskog dizelskog motora s prednabijanjem. Mada atmosfera nije sastavni dio motora, uvrštena je u model budući da iz atmosfere motor uzima zrak i u nju izbacuje ispušne plinove, tako da je atmosfera zapravo kontrolni volumen s kojim motor izmjenjuje radni medij.



Slika 3.16: Dijagram toka informacija za model brodskog dizelskog motoras prednabijanjem [2]

Opis sustava izveden je pomoću upravljačkih vektora kojima su definirana sva svojstva kontrolnih volumena, međusobna povezanost i vrste veza. Prilikom opisa kontrolnih volumena koriste se proizvoljno odabrani indeksi, koji definiraju vrstu volumena i svrstavaju ga u jednu od grupa s jednakim svojstvom. Isti se postupak primjenjuje pri opisu međusobne povezanosti kontrolnih volumena i vrsta veza [77].

Ovisno o indeksima vektora volumena i vektora veza, u modelu se kreira sustav nelinearnih diferencijalnih jednadžbi 1. reda dopunjen empirijskim i regresijskim jednadžbama za opis rubnih uvjeta, značajki pojedinih veza i značajki komponenti motora. Trajanje proračuna ovisi o broju kontrolnih volumena, broju aktivnih veza i složenosti modela komponenti motora.

Za početak proračuna kružnog procesa motora uzet je trenutak zatvaranja usisnog ventila i početak kompresije u prvome cilindru. Proračun stanja u ostalim cilindrima pomaknut je za odgovarajući fazni kut, unaprijed definiran redoslijedom paljenja. Korišten je osnovni korak integracije od 1° okretaja koljenastog vratila, a po potrebi se skraćivao zbog postizanja veće točnosti računanja u pojedinim volumenima. Integracija diferencijalnih jednadžbi izvršena je po Eulerovoj metodi. Karakteristične veličine motora, poput srednje snage, srednjega efektivnog tlaka, specifične potrošnje goriva, srednje brzine vrtnje motora i turbopuhala, srednjih temperatura i tlakova u kontrolnim volumenima itd., određuju se za nešto duži vremenski interval, odnosno za vrijeme između dvaju uzastopnih ubrizgavanja goriva u jednom redu cilindara motora.

Uz pomoć ovog pristupa opisa sistema motora izvedena je implementacija modela na računalu. Indeksi u kontrolnim vektorima volumena i veza upravljaju tijekom izvođenja programa i pozivanjem potrebnih potprograma. U radu [77] navedeno je kako se proračun modela za četverotaktni motor tog stupnja složenosti izvodi oko 2 minute po radnom ciklusu ili da je omjer vremena obrade prema realnom vremenu oko 500:1. Danas je omjer tih vremena sveden na oko 1:1 pri uporabi računala s procesorom koji radi s taktom od 700 MHz. Ta činjenica govori u prilog tome da razvoj računalne opreme donosi veliku uštedu u vremenu i omogućuje proširenje i usložnjavanje postojećih modela uz prihvatljivo trajanje proračuna.

Pri proračunu stacionarne točke dizelskog motora koji pogoni brodski vijak ili generator električne energije, u simulaciju se uključuje regulator. Ako se promijeni brzina vrtnje zbog neravnoteže energija na koljenastom vratilu, regulator podešava potrebnu količinu goriva i vraća motor na prije definiranu radnu točku. Postizanje ili održavanje radne točke potvrđuje se kontrolom konvergencije brzine vrtnje motora i turbopuhala te tlaka, temperature, ukupne mase i pretička zraka za sve kontrolne volumene. Dostizanjem stacionarne radne točke dizelskog motora, može započeti simulacija rada u nestacionarnim uvjetima prema željenom scenariju. Tijekom proračuna, odabrani parametri motora i stanja u kontrolnim volumenima bilježe se u posebne datoteke radi naknadne obrade dobivenih rezultata.

3.10 Računalno simulacijski model brodskog propulzijskog sustava sa sporohodnim dvotaktnim dizelskim motorom

Za istraživanje rada brodskog propulzijskog sustava sa sporohodnim motorom primjenjuje se metoda simuliranja dinamičkih procesa, koji se odnose na sustav i uvjete kojima je izložen. Ovakva metoda eksperimentalnog istraživanja temelji se na kompleksnom matematičkom modelu. Na temelju matematičkog modela, primjenom računala i numeričkih postupaka analize, izrađen je računalno-simulacijski model. U tom smislu je potrebno numerički postupak pretvoriti u računalni alat za inženjersku analizu, a odgovarajuća računalna aplikacija, koja na formalizirani način kodira sve korake pripadnog algoritma, pretvara računalo u pomagalo za eksperimentalna istraživanja. Proces izrade simulacijskog modela prikazan je na slici 3.17.

Za izradu računalno-simulacijskog modela korištena je računalna aplikacija MATLAB 7.0 – SIMULINK [27]. Matlab je interaktivni razvojni alat za numeričke i inženjerske primjene, temeljen na matričnim operacijama, a obuhvaća biblioteku funkcija i programske skripte za niz numeričkih metoda, dvodimenzionalnu i trodimenzionalnu grafiku, te vlastiti skriptni programski jezik. Matlab sa svojim dodacima (toolbox) za specifične namjene uključuje veliki broj funkcija i različitih objekata, te podržava i objektno programiranje. Osnovni tip podataka je matrica. Izrada računalnih aplikacija u Matlab-u



Slika 3.17: Proces izrade simulacijskog modela

uključuje i standardne elemente računalnih aplikacija, koji su po logici i sintaksi dijelom slični onima za programski jezik C.

Simulink je računalna aplikacija razvijena u Matlab okružju koja omogućuje modeliranje, simulaciju i analizu raznih dinamičkih sustava. Podržava linearne i nelinearne sustave, modelirane kako u kontinuiranom tako i u diskretnom vremenu. Kod modeliranja, u Simulink-u se koristi grafičko sučelje za crtanje modela u obliku blok-dijagrama. Simulink sadrži bogatu biblioteku generatora ulaznih signala, prikaza izlaznih veličina, linearnih i nelinearnih komponenti sustava te konektora. Ukoliko se ukaže potreba, na jednostavan način, moguće je pojedine elemente prikazati u Matlab kodovima i povezivati sa Simulink blokovima. Nakon što je model izrađen, simulacija se pokreće pomoću Simulink izbornika ili pomoću komandi direktno iz Matlab-a. Korištenjem osciloskopa ili drugih blokova za prikaz, mogu se pratiti veličine stanja i za vrijeme samog trajanja simulacije.

Računalno-simulacijski model izrađen je na temelju matematičkog nultodimenzionalnog modela pojedinih komponenti brodskog propulzijskog sustava, koje su međusobno povezane tokovima za prijenos mase i energije. Model je opisan sustavom nelinearnih diferencijalnih jednadžbi, koje su dopunjene empirijskim i korelacijskim jednadžbama kojima se opisuju komponente sustava, rubni uvjeti, te značajke pojedinih veza. Pomoću vremena simulacije definirana je promjena kuta koljena i realno vrijeme, pa se sve računate promjene stanja mogu pratiti po kutu i vremenu. Na slici 3.18 prikazana je blok-shema modela brodskog propulzijskog sustava izvedena u Matlab-Simulink računalnoj aplikaciji. Model je sastavljen od osam osnovnih elemenata koji su međusobno povezani. Kako bi se olakšalo prilagođavanje modela različitim izvedbama propulzijskih sustava sa sporohodnim dizelskim motorom kao pogonskim strojem, elementi modela su sastavljeni od



Slika 3.18: Blok-shema modela brodskog propulzijskog sustava izvedena u Matlab-Simulink računalnoj aplikaciji

modula koji su međusobno povezani vezama u jedinstvenu cjelinu.

Osnovni elementi su: regulator i pumpa goriva, cilindri motora, kolektor ispušnih plinova, kolektor zraka za ispiranje i prednabijanje cilindara, turbina, puhalo, dinamika turbopuhala i dinamika motornog mehanizma.

U cilindar motora, za vrijeme procesa ubrizgavanja goriva, dobavlja se gorivo pomoću visokotlačne pumpe. Regulator određuje zakon ubrizgavanja, odnosno regulira završetak dobave, a VIT sustav kojim također upravlja regulator definira početak dobave. Ulazne veličine za regulator i pumpu goriva su brzina vrtnje motora, zadana referentna brzina vrtnje, snaga motora i tlak u kolektoru zraka za ispiranje cilindara. Funkcija regulatora, među ostalim, uključuje i ograničenje poluge goriva obzirom na tlak ispirnog zraka, opterećenje i brzinu vrtnje. U element cilindri motora osim mase goriva po procesu dovode se i veličine stanja ispušnog i ispirnog kolektora, te brzina vrtnje motora.

Element cilindri motora sadrži module svakog pojedinog cilindra. U modulu svakog cilindra računaju se, za svaki korak simulacije, veličine stanja: temperatura, volumen, tlak, pretičak zraka, masa goriva koja izgara u cilindru, toplina koja se oslobađa izgaranjem, toplina koja se predaje stijenkama, masa plinova koja ulazi i izlazi iz cilindara za vrijeme ispuha i ispiranja, tijek izgaranja i rad. Rad u cilindru motora računa se integriranjem jednadžbe $p \, dV$ za jedan okret motora. Kako bi se promjena rada motora za vrijeme prijelaznih režima brže manifestirala, proces je podijeljen u šest dijelova, pa se računa prosječna vrijednost rada za puni period između dva uzastopna paljenja, što se pokazalo dovoljnim zbog velikih inercijskih masa motora i tereta. Promjena mase i entalpije ispušnih plinova, te pretičak zraka u ispušnim plinovima su izlazne veličine iz modula cilindara, a potrebne za element ispušnog kolektora. Mase koje ulaze u cilindre

utječu na promjene stanja u kolektoru zraka za ispiranje cilindara. U element ispušni kolektor dovodi se i veličina masenog protoka na turbini, kako bi se računale veličine stanja tlaka, temperature, plinske konstante, eksponenta adijabate, i promjene entalpije ispušnih plinova. Na stanje u ispirnom kolektoru, pored veličina dobivenih iz cilindara, utječe i maseni protok na puhalu, a za računanje temperature nakon hladnjaka zraka potreban je i omjer tlakova odnosno tlak nakon puhala. Na izlazu iz ispirnog kolektora stanje zraka je opisano temperaturom, tlakom, plinskom konstantom i eksponentom adijabate. Na osnovu veličina stanja u ispušnom kolektoru, te brzine vrtnje motora i turbopuhala u elementu turbina, računa se moment turbine i maseni protok na turbini. U elementu puhalo za svaki korak simulacije računa se moment puhala, maseni protok na puhalu i omjer tlakova.

Neke od veličina koje se prate su tlak u kolektoru zraka za ispiranje, te brzina vrtnje motora i turbopuhala. Brzina vrtnje turbopuhala računa se u elementu dinamika turbopuhala na osnovu razlike momenata na turbini i puhalu, te momenta inercije i brzine vrtnje motora. Promjenu brzine motora definira razlika između efektivne snage motora i snage tereta, koja se računa u elementu dinamika motornog mehanizma. Efektivna snaga motora i brzina vrtnje su ulazni parametri u regulator, koji je izrađen sa svim elementima stvarnog PID elektroničkog regulatora, te ispitan i potpuno usklađen s realnim.

Simulacijski model omogućuje simuliranje rada brodskih propulzijskih sustava s dvotaktnim sporohodnim motorom i vijčanim propulzorom. Jednostavna je prilagodba modela različitim izvedbama propulzijskih sustava. Simuliranjem modela na računalu s procesorom koji radi s taktom od 2 GHz, moguće je postići vrijeme simulacije približno jednako realnom vremenu, ali uz uvjet korištenja koraka računanja od 1° zakreta koljenastog vratila, izbora jednostavnijih integracijskih metoda, te pohranjivanja manjeg broja radnih parametara. Za svrhe detaljnih istraživanja, za vrijeme prijelaznih procesa ili dijelova samoga ciklusa u motoru, bira se korak računanja od 0,1° zakreta koljenastog vratila i Eulerova metoda integracije. Pri takvom koraku računanja i izboru metode integracije, na navedenom računalu, vrijeme simulacije je oko 25 puta sporije od realnog vremena. Za početak simulacije može se uzeti bilo koja radna točka za koju se prethodno trebaju dobiti početne vrijednosti iterativnim metodama. Taj prvi korak pronalaženja za pojedine točke uz promjenjeno vrijeme ubrizgavanja zna biti problematičan, pa je potrebno vrijeme ubrizgavanja postupno prilagoditi prema željenoj vrijednosti.

4 Model neuronske mreže

4.1 Uvod

Razvoj društva i tehnologije nametnuo je potrebu da strojevi i uređaji sami izvršavaju složene zadatke koji su nekad činili ljudi.

Ekonomija i gospodarstvo, globalizacija trgovine, sve veća konkurentnost na tržištu i sl. potaknulo je potrebu za brzim i ispravnim odlučivanjem. Konkurentnost na tržištu diktira smanjenje troškova uz povećanje efikasnosti. Uvode se nove tehnologije i proizvodi, koji moraju biti jednostavni pri uporabi, a izvršavati složene radnje.

Ljudski se resursi zamjenjuju uređajima i napravama baziranim na umjetnoj inteligenciji, osobito na onim poslovima koji su ponavljajući, zamorni, presloženi i kod kojih bi ljudi bili prespori, preskupi, neefikasni i imali veću vjerojatnost skupe pogreške. Računala su specijalizirana, imaju veću brzinu procesiranja od mozga, mogu neprekidno i efikasno raditi, nemaju subjektivno mišljenje i lišena su emocija.

Neke probleme je teško opisati samo pomoću jednostavnih algoritama ili matematičkih izraza. U tom slučaju potrebno je odabrati efikasnu metodu koja može pomoći u rješavanju takvih problema.

Povijest umjetnih neuronskih mreža (eng. Artificial Neural Networks, ANN) seže u 1943. godinu kad su McCulloch i Pitts predložili svoj model umjetnih neurona, dok danas umjetne neuronske mreže imaju široku primjenu. Mogu se koristiti za klasificiranje podataka, izračunavanje regresijskih krivulja, donošenje odluka, itd. Pojavljivanje neuronskog računarstva je odgovor na klasično računarstvo, a ono nastoji ostvariti ili simulirati paralelnu obradu informacija na sličan način kao i ljudski mozak dok rješava probleme. Osnovna ideja jest stvaranje računalnog modela umjetne inteligencije (eng. Artificial Intelligence, AI).

Neki vrlo važni događaji za razvoj neuronskih mreža su:

- 1943. McCulloch i Pitts predlažu McCulloch-Pitts model neurona.
- 1949. Hebb objavljuje knjigu "The Organization of Behavior", u kojoj prikazuje Hebbian sustav učenja.
- 1958. Rosenblatt uvodi jednostavnu jednoslojnu mrežu koja se danas naziva perceptron.
- 1969. Izdana je knjiga "Perceptrons", autora Minsky i Papert, koja demonstrira ograničenja jednoslojnog perceptrona nakon čega gotovo sva istraživanja ulaze u mirovanje.
- 1982. Hopfield publicira više znanstvenih radova na temu Hopfield-ovih mreža.
- 1982. Kohonen razvija samoorganizirajuće mape koje sada nose njegovo ime.
- 1986. Algoritam učenja sa povratnim širenjem (eng. *the Back-Propagation learning algorithm*) za višeslojne perceptrone ponovno je otkriven i od tog trenutka kreće razvoj cijelog znanstvenog polja.

- 1990-tih. Razvija se pod-područje mreža temeljenih na radial basis funkcijama, (eng. *Radial Basis Function Networks*).
- 2000-tih. Razvoj sklopova neuronskih mreža, vektorskih strojeva i Bayesian tehnika.

Umjetna neuronska mreža, ili jednostavno neuronska mreža, je vrsta umjetne inteligencije (računalni sustav) koji oponaša način na koji ljudski mozak obrađuje i pohranjuje podatke. Neuronska mreža ima zapisanu informaciju kao skup težinskih veza između različitih neurona koji su najmanje matematičke jedinice za procesiranje podataka.

Postoje dvije glavne vrste neuronskih mreža: neprilagodljive (neadaptivne) i prilagodljive (adaptivne). Neprilagodljivim neuronskim mrežama nazivaju se one koje su prošle fazu treniranja i takve ostanu, tj. nakon toga više ne mijenjaju svoju strukturu tijekom rada. Neprilagodljiva istrenirana mreža ponaša se kao funkcija definirana na domeni ulaznih vrijednosti. Prilagodljiva neuronska mreža, nikad nije fiksna, mijenja se i prilagođava trenutnim podacima za čitavog vremena postojanja. Koristi se u onim sustavima koji moraju učiti dok se koriste.

Neuronske mreže mogu učiti na dva načina. Kod nadziranog učenja, podaci za treniranje se sastoje od ulazno-izlaznih parova, a neuronska mreža pokušava pronaći funkciju koja, kada joj se daju ulazne vrijednosti, generira izlazne. Kod nenadziranog učenja nema distinkcije između ulaznih i izlaznih podataka (npr. grupiranje podataka prema svojstvima koja još nisu definirana). Kroz proces učenja mreža mijenja svoj ustroj, veze i težine veza.

Algoritmi za učenje mreža najčešće uključuju traženje optimalnih težinskih koeficijenata. Postoje algoritmi (npr. NEAT) koji uz promjenu težinskih koeficijenata mijenjaju i samu strukturu mreže (broj slojeva, broj neurona, i sl.). Obično algoritmi koji mijenjaju strukturu uključuju u sebe evolucijske algoritme, npr. genetske algoritme ili genetsko programiranje. Pri tome genetsko programiranje nudi najveću slobodu pri kreiranju raznih struktura mreža, kao i njihovih veza. Pri učenju, moguće je odabrati i različite aktivacijske funkcije za svaki pojedini neuron. Obično neuroni koji pripadaju istom sloju imaju jednaku aktivacijsku funkciju.

Za interpolaciju ili klasifikaciju podataka, za prepoznavanje raznih objekata, i sl., umjetne neuronske mreže moraju naučiti iz podataka kojim ih se trenira. Uspješnost predviđanja neuronskih mreža značajno ovisi o podacima s kojima se vrši treniranje.

Neuronske mreže mogu biti trenirane za izvođenje ekspertnih zadataka koji traže određeno znanje ili stručnost. Dok se za ekspertne sustave uobičajeno podrazumjeva da su simbolički i bazirani na pravilima, neuronske mreže imaju zapisano znanje u obliku težinskih veza. Pravila koja neuronska mreža mora naučiti nisu eksplicitno poznata ili unaprijed zadana nego ih je potrebno procesom "rudarenja podataka" pronaći.

Neuronske mreže nisu dobre za rješavanje svih problema. Ako već postoje bolji matematički modeli, onda je bespotrebno koristi umjetne neuronske mreže za modeliranje, osim ako ne postoji valjani razlog. Jedan od razloga za njihovo korištenje jest kod onih problema koji su presloženi za modeliranje s uobičajenim metodama. Mogu se koristiti i u slučajevima kad je njihova primjena računalno efikasnija u odnosu na klasične numeričke metode (koje su matematički iznimno složene, npr. sustavi diferencijalnih jednadžbi, višestruki integrali i sl.). Složenost modela osobito dolazi do izražaja ako se želi ugraditi u "embedded" uređaj koji ima limitirane resurse pohrane podataka i procesora.

U ovom radu koristi se umjetna neuronska mreža kao model za predviđanje određenih parametara rada brodskog dizelskog motora koji su ocjenjeni kao bitni, ali isto tako i dostupni za mjerenje. Kao izvor podataka poslužile su postojeće numeričke simulacije.

Kao alat za učenje neuronskih mreža odabran je paket (biblioteka) FANN (eng. *Fast Artificial Neural Network Library*), koja je javno dostupnog koda pisanog u programskom jeziku C. U biblioteci je implementirana višeslojna mreža sa potpunom ili djelomičnom povezanošću između neurona. Izvršava se na više hardverskih i softverskih platformi. Jednostavna je za korištenje, svestrana, dobro dokumentirana i ono najbitnije, brza.

4.2 Umjetni neuron

Najmanja jedinica umjetne neuronske mreže jest umjetni neuron. Jedan neuron čini jedinicu za procesiranje ulaznog u izlazni signal. Ono što se može definirati kao umjetni neuron mogu biti uređaji, matematički izrazi i slično. Glavna je karakteristika umjetnog neurona da reagira na podražaj, a same strukture koje se sastoje od takvih neurona imaju sposobnost učenja, tj. prilagođavanja određenom problemu.

Kao što kod mozga živih bića biološki neuroni čine složene strukture međusobnih mreža, tako kod umjetnih neuronskih mreža postoje umjetne veze između umjetnih neurona. Kod bioloških mreža veze su u obliku kemijskih procesa i električnih signala, dok su kod umjetnih neuronskih mreža veze u obliku konstanti koje se nazivaju težinski koeficijenti.

Riječ *umjetno* se naglašava, jer iako umjetne neuronske mreže oponašaju biološke, značajno se razlikuju od njih i samo su pojednostavljeni oblik biološkog neurona. Isto tako, preuzimaju se samo pojedini procesi i mehanizmi prisutni kod bioloških sustava, pojednostavljuju se i prilagođavaju matematičkim algoritmima koji se onda koriste za učenje umjetnih neuronskih mreža. Umjetne neuronske mreže koje najvjernije oponašaju biološke koriste se u medicini za proučavanje rada mozga kao i za simulaciju bolesti mozga. Neke od spoznaja u medicini integriraju se u nove algoritme za učenje umjetnih neuronskih mreža.



Slika 4.1: Prikaz neurona sa pragom

Svaki umjetni neuron ima sljedeće elemente: ulazne parametre x_i s pripadajućim težinskim koeficijentima w_k , sumatorom koji sumira ulaze na koje su istovremeno primijenjeni težinski koeficijenti (suma nakon sumatora iznosi u_k), te aktivacijski prag θ_k .

Oznake na slici 4.1 su sljedeće:

- k indeks neurona,
- p ukupni broj ulaza u neuron,
- x ulaz u neuron (jedan ili više),
- w težinski koeficijenti (daju težinu vezi) i

y – izlaz iz neurona (samo jedan).

Umjesto praga za pojedini neuron, često se koristi dodatni ulaz koji ima vrijednost 1 ili -1. Ta vrijednost pomnožena sa pripadajućom težinom veze u sumatoru neurona, daje ekvivalent vrijednosti praga. Taj dodatni ulaz najčešće se označava sa indeksom 0 i zajednički je za čitav sloj.



Slika 4.2: Prikaz neurona sa dodatnom težinom umjesto praga

Umjetne neuronske mreže mogu biti prikazane pomoću grafova smjerova sa težinama. Kroz ulazne veze dolazi do aktivacije u neuronu, a izlaz iz neurona aktivira ostale neurone kojima služi kao ulaz.

4.3 Aktivacijske funkcije

Aktivacijska funkcija za sumu svih umnožaka ulaznih neurona i njima pripadajućih težina izračunava izlaznu vrijednost iz neurona. Ako se neuron nalazi u izlaznom sloju, onda je izlaz iz neurona i konačna tražena vrijednost.

Odabir aktivacijske funkcije ovisi o problemu koji se proučava. Primjerice, ako se radi o aproksimaciji vrijednosti funkcije koja je oblika trigonometrijske ili se može razviti kao oblik trigonometrijskih funkcija, mogu se uzeti kao aktivacijske funkcije sin i cos.

Najčešće korištena aktivacijska funkcija jest sigmoidna aktivacijska funkcija koja se može koristiti kod rješavanja širokog spektra problema (npr. fitiranja podataka, filtriranja šuma, donošenja odluke).

Aktivacijske funkcije mogu biti i druge funkcije koje su montono rastuće ili padajuće i moraju imati neprekidnu derivaciju (npr. sin, cos, log). Bitno je znati da funkcije mogu imati skok ili kontinuirane vrijednosti u pojedinom području.

4.3.1 Logistička sigmoidna funkcija

Logistička sigmoidna funkcija (Slika 4.3), uz funkciju hiperboličkog tangensa, najčešće je korištena aktivacijska funkcija kod MLP mreža. Česta je njena upotreba u skrivenim slojevima, a kod problema klasifikacije podataka i u izlaznom sloju. Izraz za logističku sigmoidnu funkciju jest (4.1):

$$\operatorname{sigmoid}(x) = \frac{1}{1 + e^{-x}} \tag{4.1}$$



Slika 4.3: Logistička sigmoidna funkcija

Simetrični oblik logističke sigmoidne funkcije (Slika 4.4) jest (4.2):

symsigmoid
$$(x) = \frac{2}{1 + e^{-x}} - 1$$
 (4.2)

Simetričan oblik logističke sigmoidne funkcije ima šire područje aktivacije, a najčešće i bržu konvergenciju.



Slika 4.4: Simetrična logistička sigmoidna funkcija

Stepenaste sigmoidne funkcije su aproksimacije logističke sigmoidne funkcije sa više linearnih segmenata, njihov nedostatak je što nemaju neprekidnu derivaciju, pa se u fazi učenja neuronske mreže koristi logistička sigmoidna, a u fazi eksploatacije mreže stepenasti oblik sigmoidne funkcije. Takva funkcija brže se izračunava nego originalni oblik funkcije.

Stepenasta sigmoidna funkcija aproksimacija je sigmoidne funkcije, može je zamjeniti u fazi eksploatacije mreže jer ima manje zahtjeve za računanjem, jer je funkcija aproksimacija sigmoidne preko linearnih segmenata.



Slika 4.5: Stepenasta sigmoidna funkcija



Slika 4.6: Simetrična stepenasta sigmoidna funkcija

4.3.2 Funkcija hiperboličkog tangensa

Funkcija hiperboličkog tangensa (4.3) zna davati bolje rezultate i bržu konvergenciju, ali ponekad može doći do poteškoća pri konvergenciji u fazi učenja, u tom slučaju bolje je koristiti logističku sigmoidnu aktivacijsku funkciju.

$$\tanh\left(\frac{x}{2}\right) = \frac{1 - e^{-x}}{1 + e^{-x}} \tag{4.3}$$

4.3.3 Linearna funkcija

Linearna se funkcija često koristi na izlaznom sloju, posebno kod MLP mreža koje izračunavaju kontinuirane vrijednosti aproksimacija funkcije ili mjerenih podataka.



Slika 4.7: Linearna funkcija

4.3.4 Funkcija praga

Funkcija praga kao izlazne vrijednosti ima samo dva stanja 0 i 1 (uključeno ili isključeno). U simetričnom obliku stanja poprimaju vrijednosti -1 ili 1.



Slika 4.8: Funkcija praga



Slika 4.9: Simetrična funkcija praga

4.3.5 Limitirana linearna funkcija

Limitirana linearna funkcija ima sličan oblik kao i linearna funkcija, ali ima limitiranu gornju i donju izlaznu vrijednost. Za nesimitrični oblik donja granica je 0, a za simetričan -1.



Slika 4.10: Limitirana linearna funkcija



Slika 4.11: Simetrična limitirana linearna funkcija

4.3.6 Elliot funkcija

Obična Elliot aktivacijska funkcija može služiti za brzu aproksimaciju funkcije hiperboličkog tangensa, a simetričan oblik služi za brzu aproksimaciju sigmoidnih funkcija. Brža aproksimacija je posljedica toga što se pri izračunu vrijednosti ne koristi exponencijalna funkcija.

$$elliot(x) = \frac{0, 5x}{1+|x|} + 0, 5 \tag{4.4}$$

$$symelliot(x) = \frac{1}{1+|x|}$$
(4.5)



Slika 4.12: Elliot funkcija



Slika 4.13: Simetrična Elliot funkcija

4.3.7 Gaussova funkcija

Gaussova funkcija može se koristi
ti kod MLP mreža, ali obično se koristi kod RBFN (eng.
 $Radial \ Basis \ Function \ Networks).$

Običan oblik:

$$gauss(x) = \exp(-x^2) \tag{4.6}$$

Simetričan oblik:

$$gauss(x) = 2\exp(-x^2) - 1$$
 (4.7)



Slika 4.14: Gauss funkcija



Slika 4.15: Simetrična gauss funkcija

4.4 Modeliranje sa umjetnom MLP neuronskom mrežom

Postoje razne strukture neuronskih mreža ovisno o problemima koji se rješavaju. U praksi jedna od najčešće korištenih struktura mreže je MLP mreža. Kod MLP mreže (višeslojna perceptron mreža) neuroni su grupirani u slojeve. Veze između neurona idu iz neurona u prethodnom sloju do neurona u sljedećem sloju, tako da su neuroni iz jednog sloja u vezi samo sa neuronima iz prethodnog i iz sljedećeg sloja, dakle neuroni unutar jednog sloja nisu međusobno povezani. MLP dobro uče i na podacima koji u sebi mogu sadržavati pogrešku ili šum, premda nemaju točnost kao RBFN (eng. *Radial Basis Function Networks*) i GRNN (eng. *General Regression Neural Networks*), koje zahtjevaju podatke sa vrlo malom pogreškom.



Slika 4.16: Prikaz slojeva MLP neuronske mreže

4.5 Pristup modeliranju

Rodvold je utvrdio da se razvoj neuronskih mreža odvijao kao empirijski proces bez unaprijed zadanog plana ili metode, pa je odlučio to ispraviti. Razvio je model ugniježđene ponavljajuće petlje za razvoj neuronskih mreža koji se sastoji iz pet sljedećih koraka (Slika 4.17):

Korak 1.: Odrediti skup zahtjeva, ciljeva i ograničenja koje mora zadovoljiti neuronska mreža i to dokumentirati kao specifikaciju pod nazivom Specifikacija izvedbe neuronske mreže (eng. *Network Performance Specification*).

Korak 2.: Skupiti podatke koji će se koristiti za treniranje neuronske mreže uključujući i izvore podataka u izvornom formatu, kao i izmjene provedene na podacima. Ovaj korak rezultira s dokumentom Analiza podataka (eng. *Data Analysis Document*).

Korak 3.: Ponavljajuća petlja treniranja i testiranja jest iterativni proces u kojem se razvija arhitektura mreže koja se trenira. Prva petlja jesu Varijacije topologije umjetne neuronske mreže (eng. Variations of Artificial Neural Network Topologies), u kojoj se mijenjaju parametri same arhitekture mreže. Srednja petlja, Variacija paradigmi umjetne neuronske mreže (eng. Variations of ANN Paradigms), uključuje promjenu tipa neuronske mreže koja se koristi. Vanjska petlja, Selekcija i kombinacija ulaznih neurona (eng. Selection and Combination of ANN Input Neurons), odnosi se na izmjene ulaza neuronske mreže. Sav razvoj iz ovog koraka dokumentira se kao Sažetak treniranja mreže (eng. Network Training Summary).

Korak 4.: Implementacija mreže izvodi se kroz korištenje gotovih alata, ili kroz generiranje koda iz gotovih alata, ili kroz snimanje sirovih podataka neuronske mreže u datoteku sa kodom za izvršavanje. Implementacija se dokumentira u Integracijskom dokumentu (eng. *Network Integration Document*).

Korak 5.: Nezavisna testiranja i verifikacije ispitivanja proizlaze iz Plana testiranja podataka (eng. *Network Test Plan*) i iz dokumenta Analize podataka. Kao rezultat ovog koraka je Izvještaj o testiranju mreže (eng. *Network Test Report*) u kojem su sažeto opisana sva ispitivanja.

Projekt razvoja neuronske mreže često je u iskušenju da ignorira najbolje prakse programiranja i razvoja softvera, jer je te smjernice često teško primijeniti kod ovakvih problema. Ako se prilikom razvoja ne poduzmu sve potrebne mjere opreza kao što su kontrola podataka za treniranje, bilježenje procesa razvoja i treniranja, moguće je da je krajnji rezultat, bez obzira koliko god bio prikladno rješenje, neobjašnjiv i neponovljiv. Još jedan rizik nastaje zbog izbora arhitekture mreže koja nije prikladna za problem koji je potrbno riješiti. Odabir prikladnog algoritma utječe na izvedivost razvoja mreže, kao i njenu implementaciju. Proces odabira arhitekture i implementacije u literaturi često nije dovoljno opisan.

4.5.1 Preprocesiranje podataka

4.5.1.1 Prikupljanje podataka

Razni su izvori podataka za učenje neuronskih mreža. Neki od izvora mogu biti: mjerenja, iskustvene vrijednosti, kao i rezultati drugih simulacija.

Sam izvor podataka, kao i njegova pouzdanost utječu na uspješnost procesa modeliranja. Prije obrade podataka potrebno je provjeriti da li su podaci točni. Svaki pogrešni podatak može utjecati na performanse mreže kao i njenu ocjenu.



Slika 4.17: Rodvoldov model razvoja neuronske mreže [81]

Ako prethodno prikupljeni podaci ne zadovoljavaju, potrebno je dodatno vršiti ciljana mjerenja ili izvoditi dodatne simulacije, a sve u cilju postizanja što kvalitetnijih podataka koji mogu omogućiti bolje performanse kako prilikom treniranja mreže, tako i prilikom njene eksploatacije.

Podatke prije same faze učenja treba pripremiti. Stoga je problemu prikupljanja informacija bitno pristupiti pažljivo i ocijeniti koji su podaci potrebni. Podaci za treniranje mreže moraju biti reprezentativni i sadržavati kvalitetnu informaciju.

Neovisno o načinu prikupljanja, podaci se obično mogu prikazati tablično ili kao niz zapisa u bazi. Svaki redak ili zapis sastoji se od više stupaca ili atributa koji predstavljaju ulazne ili izlazne vrijednosti.

4.5.1.2 Ocjena i odabir podataka, ulazne i izlazne vrijednosti

Podatke je prije same selekcije potrebno statistički obraditi. Nakon obrade podaci se mogu transformirati ili skalirati radi postizanja bolje distribucije vrijednosti varijabli, a time i učinkovitijeg učenja.

Prilikom modeliranja sa neuronskim mrežama nema ograničenja na odabir ulaznih i izlaznih varijabli, bitno je samo da su u realnosti sve izlazne varijable definirane ulaznim. Ako su podaci dobiveni iz simulacija, onda je najsigurnije odabrati ulazne varijable onakve kakve su bile u simulaciji.

Kod podataka prikupljenih iz mjerenja, za ocjenu ulaznih varijabli može pomoći poznavanje problema, statističke analize, razne metode za "rudarenje podataka", kao i "metoda pokušaja i pogreške" (ova posljedna metoda obično je vremenski najzahtjevnija).

Isto tako, nisu nužno zanimljive sve izlazne varijable ili postoje poteškoće pri učenju

neuronske mreže, tada se može uzeti samo dio izlaznih varijabli ili trenirati više različitih neuronskih mreža svaku sa različitim izlaznim varijablama.

4.5.1.3 Priprema seta podataka za treniranje, validaciju i test

Prije faze učenja podaci se dijele na set podataka za učenje, set podataka za validaciju i set podataka za konačni test.

Set podataka za učenje mora jednako kvalitetno pokrivati čitavo područje opsega ulaznih i, ako je moguće, izlaznih vrijednosti dobivenih iz simulacija. Sa setom podataka za učenje vrši se treniranje mreže, a time mreža mijenja svoje veze.

Set za validaciju služi za ocjenu koliko uspješno dobiveni model neuronske mreže može predviđati na novim neviđenim podacima. Set za validaciju ima slična svojstva kao set za treniranje, ali ne sadrži podatke na kojima je mreža učila. Set za validaciju može se koristiti i u fazi učenja (npr. za određivanje prekida učenja). U tom slučaju mora se koristiti i set za test, nakon što je faza učenja završila, a u svrhu konačne ocjene performansi mreže.

Ako postoji manji set dostupnih podataka mogu se koristiti testovi krosvalidacije (eng. *crossvalidation*), ali taj postupak iziskuje još veći broj treniranja. Pri tome se potrebno vrijeme za učenje i dobivanje odgovarajućih mreža povećava, a i rezultati krosvalidacije ne mogu nadoknaditi neodgovarajući broj kvalitetnih podataka. Ako nije dostupan dovoljan broj kvalitetnih podataka, onda učenje ne može biti uspješno.

Pri odabiru podataka za učenje i kasnije prilikom ekspolatacije mreže, potrebno je imati na umu da neuronske mreže kod ekstrapolacije podataka imaju značajno veću pogrešku. Djelomično se prethodno može korigirati sa povećanjem broja točaka za treniranje koje se nalaze na rubu domene ulaznih vrijednosti.

Broj potrebnih podataka u vezi je sa željenom točnosti modela i brojem skrivenih neurona. Što je veći broj neurona (nužan uvjet za veću specijalizaciju mreže) potreban je i veći broj podataka za učenje. Isto tako, što je veća potrebna generalizacija mreže, broj skrivenih neurona se smanjuje.

4.5.1.4 Skaliranje i transformacija podataka

Za uspješno učenje neuronskih mreža poželjno je podatke skalirati (a ponekad i transformirati). Ako aktivacijske funkcije izlaznog sloja ne mogu postići vrijednosti koje su na izlazu onda je treniranje neuronskih mreža neizvedivo. Prilikom korištenja linearne aktivacijske funkcije na izlaznom sloju, skaliraje nije neophodno, ali je i dalje poželjno zbog stabilnosti procesa učenja. Obično se sve izlazne vrijednosti skaliraju u područje vrijednosti [0, 1] ili [-1, 1] ovisno o odabiru aktivacijske funkcije. Pri odabiru aktivacijske funkcije na izlazu, tj. da li ima samo pozitivne ili samo negativne vrijednosti ovisi o samim izlaznim podacima. Ako su izlazni podaci varijable koje imaju samo pozitivne vrijednosti, onda je poželjno da i aktivacijska funkcija na izlazu ima samo pozitivne vrijednosti.

Poželjno je, iako ne neophodno, skalirati podatke ulaznih varijabli. Skalirani ulazni podaci smanjuju vjerojatnost da će prevagnuti utjecaj pojedinih ulaznih varijabli nad ostalima. Skaliranje podataka i kvalitetan odabir inicijalnih vrijednosti težina veze, smanjuju vjerojatnost pojave zasićenja neurona.

Za postizanje veće brzine učenja, poželjno je da se ulazni podaci nakon skaliranja nalaze u području gdje aktivacijske funkcije imaju najveću derivaciju. Ako to nije slučaj, konvergencija je sporija.

Vrijednosti podataka koje se ponašaju po logaritamskom ili eksponencijalnom zakonu, potrebno je transformirati eksponencijalnom ili logaritamskom funkcijom.

Ako su podaci za učenje mreže bili skalirani i transformirani, prilikom eksploatacije neuronske mreže, ulazne vrijednosti moraju se skalirati i transformirati, a izlazne vrijednosti vratiti u originalnu skalu.

4.5.2 Odabir broja skrivenih slojeva i neurona u svakom sloju

Potreban broj skrivenih neurona ovisi o mnogo faktora kao što su: broj podataka za učenje, broj ulaznih i izlaznih varijabli, šum u podacima, složenost problema koji se želi naučiti, vrsta aktivacijske funkcije kao i algoritam koji se koristi za učenje.

Premali broj skrivenih neurona, dovodi do velike pogreške učenja i generalizacije zbog *under-fittinga*.

Preveliki broj skrivenih neurona rezultirat će malom pogreškom učenja, ali će učenje biti nepotrebno sporo i loše će generalizirati, osim ako se ne koristi neka od tehnika za prevenciju *over-fittinga* (npr. rano zaustavljanje učenja).

Nema pravila koje vrijedi za odabir broja skrivenih neurona. Za to je potrebna strategija. Jedna od strategija jest krenuti s manjim brojem neurona i povećavati njihov broj dok se ne postigne zadovoljavajuća pogreška.

Broj skrivenih slojeva trebao bi biti ili jedan ili dva, a rijeđe više (bez obzira što komercijalni softveri nude tu mogućnost). Za najveći broj problema dovoljno je koristiti jedan skriveni sloj. Jedan skriveni sloj bi trebao biti dovoljan kod fitiranja funkcija koje su neprekidne i monotone, a 2 ili 3 skrivena sloja kod onih gdje se očekuje prekid ili diskontinuitet.

Mreže koje su jednostavnije bolje generaliziraju i brže se izvršavaju. Stoga je potrebno odabrati najjednostavniju mrežu koja zadovoljava zadanu točnost.

4.5.3 Odabir inicijalnih vrijednosti težina

Izbor aktivacijske funkcije umnogo utječe na optimalnu brzinu učenja (autori Thimm i Fiesler), ali isto tako velik je utjecaj inicijalnih težina. Isti autori (Thimm i Fiesler) kažu da varijacije od 0.2 koja odgovaraju težinama u području [-0,77; 0,77] imaju najbolju srednju performansu za širok spektar aplikacija testiranih u njihovim istraživanjima.

U biblioteci FANN postoji nekoliko načina kreiranja inicijalnog seta težina. Najjednostavniji je način inicijalizacije svake pojedine težine na slučajnu vrijednost između -0.1 i 0.1.

Ne preporuča se uzimati veće vrijednosti jer se time povećava vjerojatnost da pojedina aktivacijska funkcija neurona prilikom učenja dođe u zasićeno područje. Ako je aktivacijska funkcija u području zasićenja, neovisno o ulaznim vrijednostima, vrijednost na izlazu iz neurona je konstantna, a time je otežano ili u potpunosti onemogućeno učenje mreže.

O odabiru inicijalnih težina uvelike ovisi uspješnost učenja. Pravi odabir inicijalnih vrijednosti težina može spriječiti poteškoće prilikom učenja zbog ulaska sustava u lokalni minimum. Rezultat mreže ovisi značajno u inicijalnim vrijednostima težina, pa je potrebno više puta ponoviti učenje sa istim podacima, ali različitim inicijalnim vrijednostima težina.

4.5.4 Proces učenja

Procesom učenja slobodni parametri neuronske mreže se mijenjaju ovisno o algoritmu. Pri učenju ulazak u lokalni minimum može značiti ili apsolutnu nemogućnost učenja ili jako sporu konvergenciju. Noviji algoritmi imaju razne taktike izbjegavanja ulaska u lokalni minimum. Taktike izbjegavanja uključuju fino podešavanje parametara poput brzine učenja ili momenta učenja.

Brzina učenja može imati presudni utjecaj na konvergenciju pri učenju neuronske mreže. Premala brzina učenja nije poželjna zbog dugog vremena trajanja, a prevelika brzina učenja može uzrokovati divergenciju, tj. onemogućiti učenje (Slika 4.18).



(a) Premala brzina učenja (b) Prevelika brzina učenja

Slika 4.18: Utjecaj brzine učenja na konvergenciju

Proces učenja odvija se po epohama. U svakoj epohi mreži se podastiru svi podaci iz seta za treniranje.

Kod *online* učenja koeficijenti težina se korigiraju nakon svakog pojedinog zapisa iz seta učenja, a u *offline* načinu rada tek nakon čitavog seta.

Korigiranje težinskih koeficijenta ovisi o odabranom algoritmu učenja, a osnova jest minimizacija pogreške na izlaznim varijablama.

Funkcija za ocjenu pogreške može se pisati kao:

$$E_{\rm SSE}(w_{ij}) = \frac{1}{2} \sum_{p} \sum_{j} \left(targ_j - out_j \right)^2 \tag{4.8}$$

Izraz (4.8) poznat je kao suma kvadrata pogreške. Radi se o totalnoj kvadratnoj pogrešci sumiranoj preko svih izlaznih jedinica j i svih uzoraka za treniranje p. Cilj učenja jest minimiziranje pogreške iz pethodnog izraza prilagođavanjem težina w_{ij} . Obično se prilagođavanje vrši kao serija malih promjena $w_{ij} \rightarrow w_{ij} + \Delta w_{ij}$ dok pogreška $E_{\text{SSE}}(w_{ij})$ ne postane "dovoljno mala". Pristup tome zahtjeva poznavanje kako pogreška $E_{\text{SSE}}(w_{ij})$ varira kroz promjenu w_{ij} . To npr. može biti gradijent E od w_{ij}

Pravilo učenja perceptrona algoritam je koji prilagođava težinske koeficijente w_{ij} u cilju minimiziranja razlike između stvarnih izlaza out_j i onih koji su željene ciljne vrijednosti $targ_j$:

$$\Delta w_{ij} = \eta (targ_j - out_j) in_i \tag{4.9}$$

Pravilo učenja perceptrona proizlazi iz pravila Delta:

$$\Delta w_{kl} = \eta \sum_{p} (targ_l - out_l) \cdot f'\left(\sum_{n} in_n w_{nl}\right) in_k \tag{4.10}$$

Postoje brojni algoritmi za učenje mreža, i svaki ima svoju uspješnu primjenu kod određenih problema. Ne postoji univerzalno dobar algoritam.

Nakon svake epohe, za ocjenu pogreške i prekid učenja može se koristi set podataka za validaciju. Uvjeti za prekid učenja neuronske mreže mogu biti ili postotak uspješne klasifikacije ili odstupanja željenih i dobivenih izlaznih vrijednosti.

Ako je dobivena manja srednju pogreška na testnim podacima od one na podacima za učenje, to može biti indikator da je uzeo premalo podataka za testiranje. U tom slučaju potrebno je ponoviti podjelu podataka (set za učenje, set za validaciju, set za konačni test) i učenje mreže.

4.5.5 Analiza rezultata mreže

Neke od stvari koje je potrebno provjeriti pri analizi mreže jesu:

- Provjeriti da li je mreža naučila ispravne podatke, ili je možda naučila neke druge koji su u korelaciji.
- Da li je mreža konvergirala u lokalni minimum.
- Kako će se mreža ponašati u situacijama kad joj se postave podaci koji su izvan područja u kojem je trenirana ili ako joj se daju podaci na kojima nije učila.
- Da li mreža koristi pravi set ulaznih parametara za rješavanje problema.

Rizici za neuspjeh uključuju nedostatan broj podataka za treniranje, kao i sama podjela podataka za treniranje i testiranje. Zbog nedostatnosti podataka, neuronska mreža možda neće biti u stanju generalizirati ili specijalizirati učenje. Uz nedovoljan broj podataka za testiranje, teško je ispitati da li je neuronska mreža ispravno naučila i da li je sigurna i pouzdana. Oba seta i za treniranje i testiranje moraju predstavljati sve podatke iz domene, a ne samo nekoliko ograničenih primjera.

Pogrešno odabrana fiksna struktura mreže uzrokuje loše performanse. Ako je mreža premala ne može dovoljno dobro opisivati željenu funkciju. Ako je prevelika neće moći dobro generalizirati na podacima na kojima nije učila. Previše težina dovodi do mogućeg *over-fittinga*. Stoga optimalnu strukturu mreže možemo promatrati kao zasebni problem u kojem je veliki prostor potencijalnih rješenja koje treba istražiti.

4.5.6 Optimizacija strukture MLP mreže

U ulaznom sloju broj neurona jednak je broju ulaznih varijabli seta podataka za učenje, a u izlaznom sloju nalazi se onoliko neurona koliko ima izlaznih varijabli.

Optimiziranje strukture MLP mreže, ako zadovoljava pogrešku, može uključivati smanjivanje broja skrivenih neurona, a ako mreža dobro generalizira, ali ne zadovoljava pogrešku, postupno se dodaju skriveni neuroni. U postupcima dodavanja i oduzimanja skrivenih neurona potrebno je ponoviti učenje. Odabir neurona po skrivenim slojevima nije jednostavan, obično je to iskustveni broj. Za njihovo određivanje postoje dvije taktike. Jedna je početi sa manjim brojem neurona pa im povećavati broj, ili uzeti veći broj neurona pa ga smanjivati.

Obično je povoljnije početi sa manjom mrežom, i prva koja zadovolji može se uzeti kao rješenje.

Kod prevelikog početnog broja skrivenih neurona ANN može imati problema sa učenjem. Veći broj neurona ima za posljedicu još veći broj težinskih koeficijenta i veću vjerojatnost ulaska u lokalni minimum. Isto tako, mreža može "predobro" naučiti na podacima za treniranje i imati značajno lošije rezultate na podacima za validaciju.

Kod mreža sa manje neurona manja je vjerojatnost da se dogodi lokalni minimum prilikom učenja, *over-fitting* i mreža bolje generalizira. Istovremeno, premali broj neurona može onemogućiti mrežu da prilikom učenja zadovolji unaprijed zadanu pogrešku.

Jedna od optimizacija, nakon što mreža prođe fazu učenja, jest pronalaženje i brisanje veza sa težinskim koeficijentima koji su jednaki ili bliski vrijednosti nula. Dodatno se mogu ukloniti veze i neuroni koji ne doprinose velikoj razlici u rezultatu. Ova procedura se može iterativno ponavljati, sve dok se dobiva jednostavnija struktura, a da je unaprijed zadana pogreška zadovoljena.

Biblioteka koja se koristila u radu ima mogućnost kaskadnog učenja. Time mreža kreće od jednostavne strukture koja se postupno povećava i postaje složenija (dodaju se veze, izmjenjuju se aktivacijske funkcije, i slično) dok se ne zadovolje zadani uvjeti.

Isto tako i broj veza je bitan za performanse (a nekad i samu točnost proračuna). Neke mreže imaju punu povezivost, dok neke imaju djelomičnu. Zadavanje djelomične povezivosti ubrzava vrijeme učenja, jer je potrebno naći manji broj težinskih koeficijenata.

Kod kreiranja mreže potrebno je definirati veliki broj parametara poput broja slojeva, neurona i veza koje moraju imati. Sve je to bitno za performanse mreže.
5 Modeliranje neuronske mreže na simulacijskom modelu brodskog dizelskog motora

5.1 Osnovni podaci o motoru

Izvorni sporohodni brodski motor 6S50MC MAN&BW, čiji su podaci upotrebljeni za numeričke simualcije, nije predviđen za varijabilno ubrizgavanje goriva i varijabilno upravljanje s ispušnim ventilom. To je moguće učiniti kod motora istog proizvođača, koji umjesto oznake MC izvornog motora imaju novu oznaku MCE za "inteligentnu" varijantu istoga motora (elektronički upravljan elektrohidraulički pogon ispušnih ventila i ubrizgavanja goriva).

Proces	2 taktni, izravno ubrizgavanje
Broj cilindara	6 u liniji
Promjer cilindra	500 mm
Stapaj	1910 mm
Redoslijed paljenja	1-5-3-4-2-6
Maksimalna trajna snaga	8580 kW
Maksimalna trajna brzina vrtnje	127 min-1
Maksimalni srednji efektivni tlak	18 bara
Maksimalni tlak izgaranja	143 bara
Specifična potrošnja goriva (s tur- bopuhalom velike efikasnosti)	171 g/(kWh), 100% opterećenja
Stupanj kompresije (dobiven proračunom)	17,2 (ovisi o podlošci ispod stapaice)
Omjer polužja	0,436
Volumen ispušnog kolektora	$6,13 \text{ m}^3$
Volumen kolektora ispirnog zraka (ukupni s rashladnikom zraka)	$7,179 \text{ m}^3$
Masa motora	232 000 kg

Tablica 5.1: Osnovni podaci analiziranog motora 6S50MC MAN&BW [82]

Smjerovi razvoja inteligentnih sustava upravljanja idu prema većoj adaptivnosti pri različitim režimima plovidbe osobito u radu u teškim uvjetima (npr. valovito more) gdje se pojavljuju tranzijenti u kojima je značajnija potrošnja goriva. Pri zadovoljavanju zadanih granica emisije NOx, SOx i čađe, važna je prije svega je pouzdanost.



Slika 5.1: Poprečni presjek dizelskog motora 6S50MC MAN&BW

5.2 Prikupljanje podataka iz simulacije



Slika 5.2: Usporedba izmjerenih vrijednosti i rezultata simulacije u stacionarnim točkama, pri: 25%, 50%, 75%, 93,5%, 100% i 110% opterećenja motora [82]

Slika 5.2 prikazuje usporedbu rezultata numeričkih simulacija s izmjerenim vrijednostima pri ispitivanju motora u tvornici proizvođača. Iz slike se vidi dobro poklapanje izmjerenih vrijednosti i rezultata s ispitnog stola. Ovo dobro poklapanje preduvjet je za kvalitetne numeričke simulacije svih ostalih režima rada motora. Stoga je korišteni simulacijski model prihvaćen kao osnova za prikupljanje podataka koji su poslužili za razvoj modela baziranog na neuronskoj mreži. Podaci se prikupljuju u bazu iz koje se kasnije prema potrebi koriste oni koji su potrebni za simulaciju, isto tako, time je moguće definirati što su ulazni, a što izlazni podaci.

Obzirom da se pri izradi ovoga rada nije raspolagalo s velikim setom potrebnih izmjerenih podataka za različite režime rada motora korišteni su podaci dobiveni primjenom numeričkih simulacija. Suvremeni brodski dizelski motori s elektrohidrauličkim upravljanjem ubrizgavanja goriva i otvaranja ispušnog ventila, koji se nazivaju "inteligentnima" omogućuju vrlo veliko područje mogućnosti prilagodbe motora nametnutim režimima rada. Ovo cijelo područje je inače preveliko za kompletno ispitivanje motora, tako da nisu javno dostupni kvalitetni podaci mjerenja. Upravo je to bio razlog da su se u provedbi ovih istraživanja koristili podaci dobiveni numeričkim simulacijama.

Primjenom numeričkih simulacija bezopasno po motor možemo istražiti uvjete rada i za područja koja nisu pokrivena garantnim uvjetima proizvođača. To je dodatni razlog zašto su korišteni rezultati numeričkih simulacija. Kako se u ovom slučaju radi o brodskom dvotaktnom dizelskom motoru s prednabijanjem, potrebno je istaknuti da je problem prednabijanja turbopuhalom posebno zahtjevan upravo kod ovakvih motora. Za razliku od četverotaktnih motora s prednabijanjem, gdje sam motor može djelovati i kao zračna pumpa za pogon turbine turbopuhala, dvotaktni motor to nije u stanju. Da bi se postiglo nužno ispiranje cilindra motora radi izmjene radnoga medija mora biti ispunjen uvjet da je tlak zraka iza puhala veći od tlaka na ulazu u turbinu turbopuhala. Da bi turbopuhalo moglo ispuniti tu zadaću potrebna je visoka temperatura i protok ispušnih plinova, što nažalost nije ispunjen uvjet u cijelom radnom području dvotaktnog motora. Obzirom na osnovno podešavanje kuta početka ubrizgavanja goriva i početka otvaranja ispušnog ventila, drugačija podešavanja tih kuteva mogu pogoršati ili dijelom poboljšati uvjete prednabijanja i ispiranja cilindra. Kako će biti pokazano, uvjeti prednabijanja i ispiranja cilindra dobro su ispunjeni pri višim opterećenjima i brzinama vrtnje motora. Pokazatelj opterećenja je hod ručice goriva. Vidjeti će se da se pouzdan rad motora može postići tek iznad određenog položaja ručice goriva.

Obzirom da se unaprijed za motor nije moglo pouzdano pretpostaviti, pri odabranom podešavanju početka ubrizgavanja goriva i početka otvaranja ispušnog ventila, da li će moći postići određenu snagu ili zakretni moment kao ulazni podatak je radije korišten položaj ručice goriva. Obzirom na količinu ubrizganog goriva, koja je određena položajem ručice goriva i brzinom vrtnje motora, snaga, odnosno zakretni moment, dobiveni su kao rezultat numeričkih simulacija. Na taj način je izbjegnuta zamka da od motora tražimo da postigne određenu snagu ili zakretni moment, a da motor za nametnute uvjete to uopće nije u stanju postići. Ovako dobiveni rezultati, temeljeni na položaju ručice goriva kao ulaznom podatku, omogućili su da se dobiju svi potrebni izlazni podaci numeričkih simulacija u cijelom radnom području motora. Dobivena snaga ili zakretni moment koji su bili izlazni podaci numeričkih simulacija i obrade primjenom neuronske mreže uzeti su kasnije kao ulazni podatak za pronalaženje optimalnih karakteristika motora za nametnute uvjete rada. Za to nisu promjenjeni ulazni podaci u neuronsku mrežu, jer zbog brzine samih procedura to nije bilo potrebno.

Točnost koju pružaju korištene numeričke simulacije su sa relativnom greškom do 3% unutar glavnog dijela polja rada, a do 5% na rubovima. To je bio i preduvjet za kvalitetu učenja neuronskih mreža kako bi se njihovom primjenom dobile prognoze iste razine točnosti.

Nakon toga, poziva se rutina za podjelu podataka, a nakon podjele podaci se skaliraju i time nastaje set za treniranje, validaciju i test. Prilikom prikupljanja i odabira potrebnih podataka, potrebno je zadati i filtere, npr. specifična potrošnja goriva unutar nekih granica.

Svako modeliranje, kao i modeliranje neuronskih mreža podrazumijeva rad s podacima. Za potrebe modeliranja neuronske mreže osobito je bitno prikupljanje podataka. Neuronske mreže imaju potrebu za većim brojem podataka nego neki drugi modeli za opis pojave ili mjerenja.

Podaci su prikupljeni iz simulacijskih proračuna. Povod korištenju umjetne neuronske mreže za pronalaženje parametara rada brodskog motora jest brzina izvršavanja. Podaci koji su poslužili za treniranje i validaciju mreže generirani su iz simulacijskog modela [82].

Podaci i matematički modeli korišteni u simulaciji rezultati su rada na znanstvenom projektu "Numeričke simulacije i optimizacija brodskih dizelskih motora".

Simulacijski model daje zadovoljavajuće rezultate, ali nažalost nedostatno brzo za upravljanje u realnom vremenu. Nepraktičan je za brze analize.

Ulazni podaci za simulaciju odabrani su slučajnim odabirom u područjima definiranim u tablici 5.2. Korištenjem slučajnog odabira ulazni podaci su razasuti po ulaznoj domeni s ciljem da se osigura ravnomjerna zastupljenost vrijednosti ulaznih varijabli. Kut pomaka početka ubrizgavanja goriva SOI ima negativan predznak ako se radi o pomaku prema ranije, a pozitivan za pomak prema kasnije. Isto vrijedi i za pomicanje kuta otvaranja ispušnih ventila EVO.

Upravljanje ulaznim vrijednostima u simulaciju izvedeno je preko skripte koja je mijenjala vrijednosti parametara odgovarajućih blokova unutar simulinka.

Kao rezultat svake pojedine simulacije stvarao se zapis koji je sadržavao ulazne parametre, kao i izlazne vrijednosti iz simulacija koje su se promatrale. Prikaz podataka koji su činili zapis svake simulacije prikazan je u tablici 5.3

Varijabla	Vrijednosti sa kojima se ulazilo u simulaciju
n_{M}	od 75 do 130
x_{reg}	od 12 do 82.7
SOI	od -10 do +10
EVO	od -20 do +20

Tablica 5.2: Vrijednosti ulaznih parametara

Stupac	Oznaka	Opis				
Oznaka konvergencije						
1	1 Konvegencija (1-Da, 0-Ne)					
Ulazne vrijednosti						
2	$n_{ m M}$	Broj okretaja motora				
3	x_{reg}	Pomak letve regulatora goriva				
4	SOI	Pomak ubrizgavanja				
5	EVO	Pomak otvaranja ispušnih ventila				
Izlazne vrijednosti						
6	$M_{\rm M}$	Zakretni moment na motoru				
7	$P_{\rm ef}$	Snaga motora				
8	$b_{ m e}$	Specifična potrošnja goriva				
9	$T_{\rm IK}$	Temperatura u ispušnom kolektoru				
10	$T_{\rm izl,T}$	Temperatura na izlazu iz turbine				
11	$T_{\rm UK}$	Temperatura u usisnom kolektoru				
12	$m_{\rm prot,T}$	Maseni protok na turbini				
13	$\lambda_{ m IK}$	Pretičak zraka u ispušnom kolektoru				
14	$p_{ m UK}$	Tlak u usisnom kolektoru				
15	$p_{\rm IK}$	Tlak u ispušnom kolektoru				
16	n_{TP}	Brzina vrtnje turbopuhala				
17	$m_{\rm prot,P}$	Maseni protok na puhalu				
18	$p_{\rm max}$	Maksimalni tlak u cilindru				
19	$T_{\rm max}$	Maksimalna temperatura u cilindru				
20	$Q_{\rm st}$	Toplina predana stijenkama cilindra				

 Tablica 5.3:
 Opis dobivenog zapisa kao rezultat svake pojedine simulacije



5.2.1 Histogrami svih podataka za koje se vršila simulacija

Slika 5.3: Histogrami ulaznih podataka u simulacijama

Bitno je analizirati podatke s kojima se ulazi u simulaciju. Sama simulacija je složen proces i simulacijski model ne mora riješiti problem za sve zadane ulazne vrijednosti. Stoga je potrebno promatrati sa kojim se podacima ulazi u simulaciju, za koje je podatke simulacija konvergirala, a za koje nije. Kod ulaznih podataka bitno je osigurati raspršenost podataka, tako da se što kvalitetnije pokrije kompletna domena ulaznih vrijednosti. To u histogramu predstavaljaju podjednake učestalosti vrijednosti ulazne varijable po svakom segmentu.

Kao osiguranje od "pucanja" simulacije i nemogućnosti njenog daljnjeg izvršavanja, svaka se simulacija za svaki set ulaznih parametara provodi zasebno kao neovisni proces.

Ako se proces pojedine simulacije uspješno završi, rezultat simulacije se bilježi u obliku zapisa. Ovisno o statusu konvergencije, zapis rezultata bilježi se ili u bazu onih koji su konvergirali ili u bazu onih koji nisu konvergirali.

U slučaju da je zbog numeričke nestabilnosti proces simulacije prestao prije kraja regularnog izvršavanja, nema rezultata koji bi se mogao prikupiti, već se nastavlja petlja izvršavanja nove simulacije s novim slučajno odabranim ulaznim podacima. Svaki takav događaj u kojem pojedina simulacija "pukne" može se bilježiti.

Razdioba podataka po slučajnom odabiru omogućuje kvalitetniju informaciju u odnosu na strukturiranu razdiobu ulaznih podataka. To posebno vrijedi za slučajeve kad se želi pri učenju neuronske mreže zamjeniti izlazna varijabla sa ulaznom, što se posebno željelo postići u ovome radu. U histogramima svih podataka za koje se vršila simulacija (Slika 5.3) prikazani su oni ulazni podaci za koje je simulacija ili konvergirala ili divergirala. Ulazni podaci za koje pojedina simulacija nije uspjela regularno završiti (tj. "puknula je") nisu prikazani u histogramima (takvih zapisa ima 10-tak na više od 3000 podataka, tj. ukupno manje od 0.3%).

U histogramima se može vidjeti da su ulazne vrijednosti bile podjednako zastupljene.

200 200 150 Učestalost 150 Učestalost 100 100 50 50 0 0L 10 90 110 130 80 100 120 20 30 40 60 70 80 50 min^{-1} $n_{ m M}$, x_{reg} , mm (a) Brzina vrtnje motora $n_{\rm M}$ (b) Položaj ručice regulatora $x_{\rm reg}$ 300 300 250 250 Učestalost Jčestalost 200 200 150 150 100 100 50 50 <u>0</u> _10 0 5 -5 0 10 20 -15 -10 0 5 10 15 20 -5 ° KV SOI, °KV EVO. (c) Pomak kuta ubrizgavanja SOI (d) Pomak kuta otvaranja ispušnih ventila EVO

5.2.2 Histogrami ulaznih simulacijskih podataka, konvergirajući

Slika 5.4: Histogrami ulaznih simulacijskih podataka, konvergirajući

Na histogramima podataka za koje je sustav konvergirao (Slika 5.4) vidi se da neke vrijednosti pojedinih varijabli imaju značajan utjecaj na moguću konvergenciju. Iz slike 5.4(b) vidi se da grupa korištenih podataka raste od položaja ručice goriva 40 mm na više. Razlog tome je bio u činjenici da je ta pojava određivala minimalnu količinu goriva potrebnu za stabilni rad turbopuhala s dvotaktnim motorom. Kod viših količina goriva rad je bio još stabilniji čak i pri promjenama kuteva početaka ubrizgavanja goriva i otvaranja ispušnog ventila. Neki od tih rezultata bili su očekivani. Položaj letve goriva ima najveći utjecaj na konvergenciju i to je bio očekivani rezultat. Kao najmanji mogući položaj ručice goriva odabrana je vrijednost od 12 mm. To je njen najniži mogući fizički položaj. Pri nižim položajima ručice, manja je dobava goriva, a u tim režimima motor nema dovoljnu količinu goriva za stabilni rad sustava prednabijanja i ispiranja. U takvim slučajevima se za eksploataciju motora koriste dodatni električki pokretani ventilatori i takav rad se dopušta u iznimnim slučajevima, koji u ovom radu nisu istraživani. Druga

utjecajna veličina jest pomak kuta početka ubrizgavanja goriva SOI (eng. Start of Injection). Pri pomaku kuta početka ubrizgavanja na kasnije, izgaranje u cilindru motora kasni i smanjuje se rad dobiven ekspanzijom, pa u tom slučaju snaga motora smanjuje.



5.2.3 Histogrami ulaznih simulacijskih podataka, divergirajući

Slika 5.5: Histogrami ulaznih simulacijskih podataka, divergirajući

Histogrami ulaznih podataka za koje simulacija nije konvergirala prikazuju isti utjecaj položaja ručice goriva, kao i kuta pomaka ubrizgavanja, obzirom na konvergenciju. Razlog za atipični izgled slike 5.5(b) pojašnjen je u poglavlju 5.2.2 u tekstu vezanom za sliku 5.3.

Podaci numeričkih simulacija koji nisu uspjeli konvergirati, a koji su ovdje nazvani "divergirajući" odnose se na situacije kada je u nametnutim uvjetima, definiranim ulaznim podacima, došlo do značajnijih nestabilnosti u numeričkoj shemi. Do tih je nestabilnosti došlo zbog dinamike komponenti sustava koji čine brodski dvotaktni dizelski motor, a da se nije uspjela postići stabilna radna točka motora. Takve situacije pojavljuju se u slučajevima kada turbopuhalo ispada iz pogona zbog narušene bilance energije između turbine i puhala, čime se prekida ispiranje motora i nužno dovodi motor u ispad iz rada. Ove situacije su učestale pri malim količinama dovedenog goriva i velikim razlikama u kutevima početaka ubrizgavanja goriva i otvaranja ispušnog ventila obzirom na njihove optimalne postavke.

5.3 Histogrami ulaznih podataka za treniranje mreže



Slika 5.6: Histogrami ulaznih podataka za treniranje mreže

Histogrami ulaznih podataka za treniranje predstavljaju učestalost svih ulaznih vrijednosti u setu podataka za treniranje. Učestalost pojedinih vrijednosti mora pokazati podjednaku relativnu zastupljenost. To nije slučaj za x_{reg} , pa je moguće da pogreška učenja za vrijednosti koje imaju manju učestalost bude veća.

Set za treniranje pokazuje da postoji nesrazmjer u distribuciji podataka za položaj ručice goriva (zbog konvergencije). Nije izvršena korekcija, pa je to utjecalo na nešto veću pogrešku kod onih podataka koji sadrže vrijednost x_{reg} sa manjom učestalosti.





Slika 5.7: Histogrami ulaznih podataka za validaciju mreže

Histogrami ulaznih podataka za validaciju mreže distribucijom bi morali pratiti oblik histograma za treniranje mreže. Time se osigurava podjednaka zastupljenost u setu podataka za učenje i validaciju, čime je validacija točnija. Histogrami prikazuju apsolutnu učestalost.

5.5 Histogrami ulaznih podataka za konačni test mreže

Histogrami ulaznih podataka za konačni test mreže distribucijom, mogu pratiti oblik histograma za treniranje mreže, ali nije uvijet. Za konačni test poželjno je imati što različitije podatke od onih sa kojima je mreža trenirana, čime se provjerava generalizacija na neviđenim podacima. U simulacijama se koristio set podataka za validaciju kao uvjet za prekid učenja mreže, stoga je bilo potrebno izvršiti dodatnu validaciju mreže sa testnim setom podataka za konačnu ocjenu.



Slika 5.8: Histogrami ulaznih podataka za konačni test mreže (ocjenu nakon treniranja)

5.6 Učenje mreže na podacima iz simulacije

Kao model neuronske mreže za učenje na podacima iz simulacija korištena je MLP neuronska mreža. Izlazna vrijednost koja se nije korištila pri učenju je snaga, jer se jednostavno može izračunati iz momenta. Lambda je korištena prilikom učenja, ali se u ekspolataciji ignorira jer se točniji rezultat dobiva korištenjem vrijednosti masenih protoka na puhalu i turbini. Isto tako, u eksploataciji nisu korištene vrijednosti topline izmjenjene sa stijenkom cilindra. Drugim riječima, neuronska mreža ima 4 ulazne varijable i 14 izlaznih varijabli od kojih u daljnjoj analizi nisu promatrane dvije (λ_{IK} i Q_{st}).

Koristio se samo jedan skriveni sloj. U skrivenom sloju koristila se sigmoidna logistička, a u izlaznom sloju linearna aktivacijska funkcija.

Pokušavalo se odabrati optimalni set inicijalnih koeficijenata težina primjenom GA. Ali to je bilo učinkovito samo kod manjeg broja skrivenih neurona.

Broj neurona u skrivenom sloju je 20, a aktivacijska funkcija sigmoidna. Pravci na slikama prikazuju područje pogreške.

Broj potrebnih neurona u skrivenom sloju određen je iz više pokušaja prema sljedećoj shemi (10,20,40,80,120). Pri tome je manji broj neurona (10) mogao pratiti generalne trendove, ali ne i zadovoljiti unaprijed zadanu pogrešku, neovisno o broju epoha. Set podataka za treniranje, validaciju i test bio je podijeljen u omjeru približno 70%-15%-15%. Iz više pokušaja učenja na podacima seta za treniranje i sa različitim početnim težinama, pokazalo se da je broj potrebnih neurona između 20 i 40. Kod mreža sa većim brojem neurona (više od 40) nastaje problem ulaska u lokalni minimum i izrazito spore

konvergencije. Nakon što se pokazalo da u većini slučajeva 40 skrivenih neurona daje najbolje rezultate, ponovilo se učenje sa istim brojem skrivenih neurona, ali se povećao broj epoha i varirali su se parametri brzine i momenta učenja. Nakon što se smanjila pogreška na podacima za treniranje, a istovremeno počela povećavati pogreška na podacima za validaciju, proces učenja je zaustavljen. Po iskustvu autora, traženje težina sa genetskim algoritmom (GA) efikasno je samo ako neuronska mreža ima manji broj skrivenih neurona. Za veći broj skrivenih neurona optimizacija primjenom GA postaje vremenski i računski suviše opsežan posao. Za vrijeme učenja, nakon svake epohe, napravljen je test srednje kvadratne pogreške na podacima za validaciju. Nakon što je učenje završilo, najbolja mreža testirana je na setu za konačni test. Pogreška na podacima za treniranje bila je najmanja (što je i potrebno), a pogreška na podacima za validaciju nešto veća. U konačnici, pogreška na setu podataka za konačni test bila je najveća, ali ne značajno veća od pogreške na setu za validaciju.

5.7 Pregled rezultata i provjera pogreške

5.7.1 Usporedba vrijednosti simulacijskih podataka i podataka dobivenih neuronskom mrežom

Pošto je nezahvalno uspoređivanje relativne pogreške na podacima koji su skalirani i obrađeni, prikaz razlike između podataka iz simulacije i podataka dobivenih iz neuronskih mreža dan je u originalnoj skali. Pri tome treba napomenuti da je napravljen izuzetak u prikazu temperatura, koje su originalno bile zadane u Kelvinima, a u grafovima su prikazane u °C. Maseni protoci bili su zadani po kutu koljenastog vratila, a transformirani su u kg/s. Podaci za temperature u skali sa °C prikazuju nešto veću pogrešku nego u skali sa stupnjevima K.

U nastavku, prikazani su grafovi odstupanja vrijednosti simulacijskih podataka i onih dobivenih neuronskom mrežom. Apscisa predstavlja simulacijski podatak, a ordinata podatak dobiven modelom neuronske mreže. Točke koje leže na crnoj kosoj liniji su točne točke. Gornja zelena crta označava relativnu pogrešku od +5%, a donja zelena linija pogrešku od -5%.

5.7.1.1 Usporedba specifične potrošnje $b_{\rm e}$ iz simulacije i dobivene neuronskom mrežom



Slika 5.9: Specifična potrošnja goriva, usporedba simulacije i neuronske mreže

Na slici 5.9 prikazana je pogreška između vrijednosti specifičnih potrošnja goriva $b_{\rm e}$ dobivenih iz simulacije i onih dobivenih iz modela neuronske mreže. Što su točke bliže crnoj liniji to je manja relativna pogreška. I podaci iz seta za učenje, kao i podaci iz seta za validaciju nalaze se gotovo u potpunosti u području od $\pm 5\%$ relativne pogreške.

5.7.1.2 Usporedba zakretnog momenta na motoru $M_{\rm M}$ iz simulacije i dobivene neuronskom mrežom



Slika 5.10: Zakretni moment na motoru, usporedba simulacije i neuronske mreže

Na slici 5.10 prikazana je pogreška između zakretnih momenata na motoru $M_{\rm M}$ dobivenih iz simulacije i onih dobivenih iz modela neuronske mreže. I podaci iz seta za učenje, kao i podaci iz seta za validaciju nalaze se gotovo u potpunosti u području od $\pm 5\%$ relativne pogreške.

5.7.1.3 Usporedba brzine vrtnje turbopuhala $n_{\rm TP}$ iz simulacije i dobivene neuronskom mrežom



Slika 5.11: Brzina vrtnje turbopuhala, usporedba simulacije i neuronske mreže

Slika 5.11 pokazuje da su uglavnom sve dobivene točke unutar reda točnosti kao i ostali ranije uspoređeni podaci. Na slici 5.11(a) vidi se da nekoliko točaka ne zadovoljava tražene uvjete točnosti. Naknadnom provjerom utvrđeno je da se te točke odnose na situacije sa malim hodom ručice goriva (ispod 40 mm) tj. pri maloj količini ubrizganog goriva što u kombinaciji s niskom brzinom vrtnje dovodi na same rubove područja pouzdanog rada sustava prednabijanja i ispiranja. Ovisno o smjeru kojim se vršilo približavanje nekoj radnoj točki, ovisi da li će motor moći raditi ili će ispasti iz pogona.

5.7.1.4 Maseni protok na puhalu $m_{\rm prot,P}$ iz simulacije i dobiven neuronskom mrežom



Slika 5.12: Maseni protok na puhalu, usporedba simulacije i neuronske mreže

Slika 5.12 pokazuje da su uglavnom sve dobivene točke unutar reda točnosti kao i ostali ranije uspoređeni podaci.

5.7.1.5 Maseni protok na turbini $m_{\rm prot,T}$ iz simulacije i dobiven neuronskom mrežom



Slika 5.13: Maseni protok na turbini, usporedba simulacije i neuronske mreže

Iz slike 5.13 vidi se dobro poklapanje podataka neuronske mreže i podataka iz simulacija. Iz usporedbe slika 5.12(a) i 5.13(a) može se vidjeti odstupanje dvije točke koje su u obje slike povezane s problematičnim režimima rada za koje su ipak postignute konvergencije rješenja iz numeričkih simulacija. Odstupanja istih točaka vidljive su i na slikama 5.14(a) i 5.15(a).

5.7.1.6 Tlak u usisnom kolektor
u $p_{\rm UK}$ iz simulacije i dobiven neuronskom mrežom



Slika 5.14: Tlak u usisnom kolektoru, usporedba simulacije i neuronske mreže

Svi podaci su većinom unutar dopuštenih odstupanja, osim dvije točke na slici 5.14(a), o čemu je rečeno u poglavlju 5.7.1.5.





Slika 5.15: Tlak u ispušnom kolektoru, usporedba simulacije i neuronske mreže

Svi podaci su većinom unutar dopuštenih odstupanja, osim dvije točke na slici 5.15(a), o čemu je rečeno u poglavlju 5.7.1.5.

5.7.1.8 Temperatura u ispušnom kolektor
u $T_{\rm IK}$ iz simulacije i dobivena ne-uronskom mrežom



Slika 5.16: Temperatura u ispušnom kolektoru, usporedba simulacije i neuronske mreže

Usporedba za temperature u ispušnom kolektoru pokazuje znatnije rasipanje obzirom na usporedbe ranijih podataka. Razlog tome mogu biti utjecaji promjene tlaka u ispušnom kolektoru i protoka na turbini turbopuhala za pojedine upitne radne točke. Obzirom da je ovdje korišten prikaz temperature u °C, a mreža je učena s temperaturama u K, to je dodatno naglasilo odstupanja.

5.7.1.9 Temperatura u usisnom kolektor
u $T_{\rm UK}$ iz simulacije i dobivena ne-uronskom mrežom



Slika 5.17: Temperatura u usisnom kolektoru, usporedba simulacije i neuronske mreže Iz slike 5.17 je vidljivo da su poklapanja podataka unutar dopuštenih odstupanja.

5.7.1.10 Maksimalni tlak proces
a p_{\max} iz simulacije i dobiven neuronskom mrežom



Slika 5.18: Maksimalni tlak procesa, usporedba simulacije i neuronske mreže

Iz slike 5.18 je vidljivo da su poklapanja podataka unutar dopuštenih odstupanja.

5.7.1.11 Temperatura na izlazu it turbin
e $T_{\rm izl,T}$ iz simulacije i dobivena ne-uronskom mrežom



Slika 5.19: Temperatura na izlazu iz turbine, usporedba simulacije i neuronske mreže

Iz slike 5.19 vide se značajnija odstupanja neuronske mreže i rezultata simulacija. Iz slike 5.19(a) vidi se da su odstupanja na podacima za treniranje veća, što može upućivati na činjenicu da se u većem broju podataka za učenje nalazi i veći broj rizičnih podataka. Iz slike 5.19(b) vidi se da naučena mreža na podacima za validaciju daje manja odstupanja nego na podacima za učenje. Razlog tome je u činjenici da u manjem setu podataka za validaciju ima i manje rizičnih podataka.

5.7.1.12 Maksimalna temperatura proces
a $T_{\rm max}$ iz simulacije i dobivena neuronskom mrežom



Slika 5.20: Maksimalna temperatura procesa, usporedba simulacije i neuronske mreže

Podaci na slici 5.20 pokazuju dobra poklapanja i na setu podataka za učenje i na setu podataka za validaciju.

5.7.2 Osvrt na analizu pogreške

Iz prikazanih usporedbi vidljivo je da se podaci neuronske mreže i podaci dobiveni iz numeričkih simulacija uglavnom poklapaju unutar dopuštenih odstupanja. Zapažena odstupanja u većini usporedbi odnose se na problematične kombinacije ulaznih podataka obzirom na mogući rad motora. Tu se prije svega misli na rad motora s malim količinama ubrizganog goriva, pri čemu se očekuju problemi u radu turbopuhala i samoga motora. Za niske vrijednosti $x_{\rm reg}$ koje su manje zastupljene i koje upućuju na mogući problematični rad sustava za prednabijanje i ispiranje, pogreška je veća, kao i za rubne vrijednosti ulaznih varijabli.

Razvijeni model neuronske mreže u potpunosti je pripremljen za prihvat novih podataka izmjerenih tijekom eksploatacije motora. Očekuje se da će se učenjem mreže na dodatnim podacima iz eksploatacije motora, popraviti kvaliteta rezultata neuronske mreže. Prvim usporedbama izmjerenih podataka i podataka neuronske mreže moći će se ocjeniti kvaliteta izmjerenih podataka i cijelog mjernog sustava. Ta ocjena je preduvjet za kasnije analize mogućih odstupanja sustava od očekivanih normalnih stanja za potrebe dijagnostike nadolazećih kvarova.

Unatoč svemu može se zaključiti da je primijenjena neuronska mreža u stanju zamjeniti numeričke simulacije s dovoljnom točnosti. Postignuti rezultati upućuju na mogućnost pouzdane primjene takve neuronske mreže u sustavima regulacije motora.

Opterećenje motora (od MCR)	25 %	50 %	75 %	93.5 %	100 %	110 %
Indicirana snaga (kW)	2401	4406	6580	8170	8656	9499
Efektivna snaga (kW)	2142	4099	6160	7667	8182	9014
Brzina vrtnje (min ⁻¹)	76,5	96	110,4	118,5	121,4	125,2
Indeks regulatora	44,3	55,4	68,1	77,3	79,2	85.8
Tlak kompresije (bar)	46,2	70,3	97,5	117,6	123,7	137,8
Maksimalni tlak izgaranja (bar)	66,6	97,4	129,6	143,3	141,4	139,3
Srednji indicirani tlak (bar)	8,37	12,24	15,89	18,38	19,01	20,23
Položaj poluge goriva (mm)	39,7	50,3	63,3	73	75	81,8
Tlak ispirnog kolektora (bar)	1,394	2,03	2,76	3,33	3,55	3,93
Temp. u ispirnom kol. (°C)	25	29	34	40	41	45
Tlak ispušnog kolektora (bar)	1,3	1,86	2,51	3,06	3,26	3,64
Temperatura prije turbine (°C)	308	327	346	384	404	458
Brzina vrtnje t. puhala (min ⁻¹)	7290	11360	13870	15360	15895	17110
Spec. potrošnja gori. (g/(kW·h))	186,83	174,06	171,18	171,82	174,66	/

5.8 Primjer vrijednosti neuronske mreže za puno opterećenje motora

Slika 5.21: Podaci mjerenja na ispitnom stolu [82]

Sukladno podacima mjerenja motora na ispitnom stolu, puno opterećenje motora postiže se pri brzini vrtnje $n_{\rm M} = 121.4 \, {\rm min^{-1}}$ i položaju ručice goriva na $x_{\rm reg} = 75 \, {\rm mm}$. U tablici na slici 5.21 prikazani su glavni podaci dobiveni mjerenjem motora na ispitnom stolu pri različitim opterećenjima po krivulji brodskog vijka. Ovi podaci poslužiti će za usporedbu vrijednosti neuronske mreže pri punom opterećenju motora. Prikazane vrijednosti neuronske mreže odnose se na utjecaj promjene kuteva početka ubrizgavanja goriva (SOI) i otvaranja ispušnog ventila (EVO). Referentna točka podešavanja ispitanog motora je na nultim pomacima kuteva. Ta točka odgovara optimalnom podešavanju koje je odredio proizvođač motora. Ispitani motor nije imao mogućnost prikazanog podešavanja, koje je moguće samo kod "inteligentnih" motora.

Iz slike 5.22 vidi se utjecaj pomicanja početka ubrizgavanja goriva i otvaranja ispušnog ventila. Vidljiv je vrlo slabi utjecaj pomaka početka otvaranja ispušnog ventila. Za razliku od početka otvaranja ispušnog ventila, kut početka ubrizgavanja goriva ima mjesta postizanja maksimalnog zakretnog momenta odnosno snage motora nakon čega prema kasnijem početku ubrizgavanja i moment i snaga počinju sve brže opadati.



Slika 5.22: Zakretni moment motora $M_{\rm M}$, kNm

Na slici 5.23 prikazana je efektivna snaga motora koja je linearno proporcionalna zakretnom momentu motora (Slika 5.22). Dobivena efektivna snaga od 7,67 MW odgovara vrijednosti izmjerenoj na ispitnom stolu.



Slika 5.23: Snaga motora P_{ef} , MW;

Na slici 5.24 prikazana je specifična potrošnja goriva motora. Iz slike je vidljivo da bi se moglo lako odrediti i optimalno područje rada motora za navedene ulazne podatke. Tu se vidi mogućnost dodatnog finog optimiranja rada motora. Očekivano se sa smanjenjem snage motora pri kasnijem ubrizgavanju goriva za istu količinu ubrizganog goriva dobiva veća specifična potrošnja goriva.

Na slici 5.25 prikazan je tlak u ispušnom kolektoru, a na slici 5.26 prikazana je temperatura u istome kolektoru. Stanje tlaka i temperature definira radne uvjete turbine



Slika 5.24: Specifična potrošnja goriva $b_{\rm e},~{\rm g/kWh}$



Slika 5.25: Tlak u ispušnom kolektoru $P_{\rm IK},~{\rm MPa}$



Slika 5.26: Temperatura u ispušnom kolektoru $T_{\rm IK}$, °C

turbopuhala. Maksimalne vrijednosti tlaka i temperature uzajamno se dobro prate i postižu se pri malo kasnijem ubrizgavanju goriva obzirom na referencu. Kasnije otvaranje ispušnog ventila doprinosi većim maksimalnim vrijednostima. Na maksimalnim vrijednostima tlaka i temperature u ispušnom kolektoru snaga tubopuhala bit će najveća.



Slika 5.27: Brzina vrtnje turbopuhala $n_{\rm TP}/1000$, min⁻¹

Na slici 5.27 prikazana je brzina vrtnje rotora turbopuhala pri kojoj je postignuta ravnoteža između snage turbine i snage za pogon puhala. Očekivano, mjesta najvećih brzina vrtnje podudaraju se s mjestima maksimalnih tlakova i temperatura u ispušnom kolektoru.

Na slici 5.28 prikazana je temperatura ispušnih plinova nakon ekspanzije u turbini turbopuhala. Ta temperatura je jedan od važnih parametara za ocjenu moguće utilizacije



Slika 5.28: Temperatura iza turbine turbopuhala $T_{izl,T}$, °C

otpadne topline motora. Obzirom na relativno veliki dio zraka za ispiranje, koji samo projuri kroz cilindar i dospije u ispušni kolektor, temperatura ispušnih plinova relativno je niska. To smanjuje mogućnosti utilizacije otpadne topline, pa je svako povećanje ove temperature dragocjeno. Iz slike se vidi da bi se pri kasnom otvaranju ispušnog ventila za optimalni kut ubrizgavanja goriva moglo postići željeno povećanje temperature ispušnih plinova. Iz slike 5.23 je vidljivo vrlo blago smanjenje snage motora pri kasnijem otvaranju ispušnog ventila.

Na slici 5.29 prikazan je maseni protok ispušnih plinova kroz turbinu turbopuhala. Na slici se vidi zasićenje vršnih vrijednosti masenog protoka u širem području pomaka početka ubrizavanja goriva i početka otvaranja ispušnog ventila. Kao posljedica toga, na slici 5.30 vidi se razdioba toplinske snage ispušnih plinova koja sliči razdiobi temperature ispušnih plinova. Vidi se da se radi o velikim toplinskim snagama koje se mogu utilizacijom iskoristiti za potrebe brodskog pogonskog postrojenja.

Iz slika 5.31 i 5.32 vidi se očekivana razdioba vrijednosti, slično onome što je rečeno za ispušni kolektor i stanje ispred turbine. Na mjestima vršnih snaga turbine turbopuhala imamo i vršne tlakove i temperature u usisnom kolektoru kao posljedicu veće snage za pogon puhala.

Na slici 5.33 prikazana je razdioba maksimalnih vrijednosti tlaka u cilindru za različite pomake početka ubrizgavanja goriva i otvaranja ispušnih ventila. Najniže vrijednosti maksimalnoga tlaka u cilindru postižemo kasnijim početkom ubrizgavanja goriva i ranijim početkom otvaranja ispušnog ventila. Vezano za moguće povećanje toplinske snage ispušnih plinova može se očekivati blago povećanje maksimalnoga tlaka u cilindru. Na slici 5.34 prikazana je razdioba maksimalnih vrijednosti temperature procesa u cilindru. Iz slike vidimo da se maksimalna temperatura u cilindru smanjuje s pomicanjem ubrizgavanja goriva na kasnije i kasnijim otvaranjem ispušnog ventila. To upućuje na strategije za moguće smanjenje emisije dušikovih oksida. Ovdje treba biti oprezan obzirom da pri takvim uvjetima pogodnim za emisije dušikovih oksida postoji opasnost povećane emisije čađe. Korišteni model za numeričke simulacije karakteristika motora nije u mogućnosti dati prognoze za emisije čađe.



Slika 5.29: Maseni protok na turbini $m_{\text{prot},T}$, kg/s



Slika 5.30: Toplinska snaga ispušnih plinova na izlazu iz turbine Q, $\,\rm kW$



Slika 5.31: Tlak u usisnom kolektor
u $P_{\rm UK},~{\rm MPa}$



Slika 5.32: Temperatura u usisnom kolektor
u $T_{\rm UK},\,^{\circ}{\rm C}$



Slika 5.33: Maksimalni tlak u cilindru motora $p_{\max},$ MPa



Slika 5.34: Maksimalna temperatura u cilindru motora $T_{\rm max},\,^{\circ}{\rm C}$

5.9 Primjer vrijednosti neuronske mreže za 50% opterećenja motora

Radi prikaza pogodnosti neuronske mreže za varijaciju ulaznih podataka ovdje će biti prikazane samo neke od vrijednosti neuronske mreže na primjeru kada isti motor radi sa 50% opterećenja. Te se slike mogu usporediti sa ranije opisanim slikama za 100% opterećenja motora. Iz slika su vidljive vrlo slične razdiobe vrijednosti, kakve su bile i pri punom opterećenju motora. Razlike se primjećuju u obliku polja vrijednosti specifične potrošnje goriva, protoka na turbini turbopuhala i toplinske snage ispušnih plinova. Može se zaključiti da je u ovom slučaju područje optimalnoga rada motora pomaknuto na kasnije ubrizgavanje goriva obzirom na referencu. Svi trendovi promjene vrijednosti su vrlo slični onima za puno opterećenje motora.



Slika 5.35: Snaga motora P_{ef} , MW;

Na slikama 5.38 i 5.41 može se vidjeti da postoji nagli skok vrijednosti za rano ubrizgavanje goriva i kasno otvaranje ispušnog ventila. Razlog za te skokove je upitno područje rada turbopuhala, zbog čega postoji opasnost da u tim područjima motor ispadne iz pogona pri tako niskom opterećenju motora. U tim uvjetima turbopuhalo nije u stanju raditi na način da je tlak pred turbinom niži od tlak iza puhala, što je nužni uvjet za pouzdano ispiranje cilindara motora.



Slika 5.36: Specifična potrošnja goriva $b_{\rm e},~{\rm g/kWh}$



Slika 5.37: Maseni protok na turbini $m_{\rm prot,T},\,\rm kg/s$



Slika 5.38: Temperatura ispušnih plinova iza turbine $T_{izl,T}$, °C



Slika 5.39: Toplinska snaga ispušnih plinova na izlazu iz turbine Q, kW


Slika 5.40: Maksimalni tlak u cilindru motora $p_{\max},$ MPa



Slika 5.41: Maksimalna temperatura u cilindru motora $T_{\rm max},\,^{\circ}{\rm C}$

5.10 Osvrt na dobivene rezultate

Iz prikazanih rezultata neuronske mreže za puno opterećenje motora može se vidjeti veća ovisnost rezultata o pomaku početka ubrizgavanja goriva i manja ovisnost o pomaku početka otvaranja ispušnog ventila. Iz dobivenih podataka za temperaturu i toplinsku snagu ispušnih plinova može se zaključiti da se može postići povećanje otpadne toplinske snage ispušnih plinova uz neznatno smanjenje snage motora samo pomakom početka otvaranja ispušnog ventila na kasnije.

Iz slika rezultata neuronske mreže za 50% opterećenja može se vidjeti da pri tako niskom opterećenju turbopuhalo ne može ispuniti zadaću prednabijanja motora i ispiranja cilindara za pojedine kombinacije početka ubrizgavanja goriva i početka otvaranja ispušnog ventila.

Na još nižim opterećenjima uskoro se dolazi do situacije da turbopuhalo više ne može ispuniti svoju zadaću i da motor bezuvjetno ispada iz pogona, bez obzira na zadane kombinacije početka ubrizgavanja goriva i početka otvaranja ispušnog ventila. Ta situacija je inače poznata i u takvom slučaju niskih opterećenja motora uključuju se pomoćni ventilatori na električni pogon, kako bi se osigrali minimalni uvjeti za ispiranje cilindara motora. U ovom radu nije istraživan takav rad motora, obzirom da se to u eksploataciji događa vrlo rijetko.

6 Primjena razvijenog modela neuronske mreže za optimiranje uvjeta utilizacije i minimalizaciju specifične potrošnje goriva

Razvijeni model neuronske mreže omogućava brzi proračun željenih radnih parametara. Uspredba izvršena u ovom radu ukazuje da neuronska mreža, u usporedbi s numeričkim simulacijama može izračunati karakteristike motora za zadane ulazne podatke u barem 3000 puta kraćem vremenu. U vrlo kratkom vremenu moguće je preći područje unutar zadanih granica SOI i EVO i izračunati sve potrebne karakteristike. Područje pretraživanja je u rasteru od 0,5°KV. Prilikom traženja optimalnih uvjeta za potrebe utilizacije potrebno je poznavati kretanje različitih parametara koji utječu na toplinsku snagu iza turbine Q. Za zadanu brzinu vrtnje motora $n_{\rm M}$ i položaj ručice goriva $x_{\rm reg}$ toplinska snaga iza turbine mijenja se u ovisnosti o pomaku početka ubrizgavanja SOI i pomaku otvaranja ispušnog ventila EVO. Odluka koja je kombinacija najbolja najviše ovisi o specifičnoj potrošnji goriva $b_{\rm e}$, maksimalnom tlaku $p_{\rm max}$ i maksimalnoj temperaturi procesa T_{max} . Ovisno o veličinama koje se žele dobiti (najveća toplinska snaga, optimalna toplinska snaga uz minimalnu specifičnu potrošnju goriva, održavanje konstantnog momenta na motoru $M_{\rm M}$, i sl.) donosi se odluka o režimu rada koji će se odabrati. Primarni cilj je dobivanje dovoljne ili veće toplinske snage kako bi se mogao izvršiti proces utilizacije topline ispušnih plinova motora.

6.1 Upravljanje sa ciljem postizanja maksimalne toplinske snage ispušnih plinova

Za određenu brzinu vrtnje motora i položaj ručice goriva potrebno je pronaći SOI i EVO koji postižu najveći toplinski tok. U tablici su dani podaci 6.1 za referentnu toplinsku snagu izračunatu za SOI = 0 i EVO = 0, te optimalni pomaci za postizanje najveće toplinske snage ispušnih plinova.

$SOI, ^{\circ} \mathrm{KV}$	$EVO, ^{\circ} KV$	$b_{\rm e}, { m g/kWh}$	$M_{\rm M},{ m kNm}$	$P_{\rm ef},{\rm MW}$	$T_{\max}, ^{\circ}\mathrm{C}$	$p_{\rm max}, MPa$	Q, kW
0	0	173	617,77	7,67	1551,4	14,5	3987,9
3,5	20	184,7	$576,\!45$	7,15	1363,8	$15,\!55$	4366,2

Tablica 6.1:	Maksimiziranje	toplinskog t	toka za zadani	$n_{\rm M} = 118.5$	$i x_{reg} = 73$
--------------	----------------	--------------	----------------	---------------------	------------------

Slučaj u kojem je postignuta najveća toplinska snaga uspoređen je sa referentnim. Uspoređivani su karakteristični parametri što je vidljivo na slikama 6.1, 6.2, 6.3, 6.4 i 6.5. Proračun je izvršen za 93.5% opterećenja motora.

Rezultati simulacije pokazali su da se uz pomak SOI na kasnije za 3,5°KV i uz pomak EVO za 20 °KV na kasnije postiže maksimalna, za 9,5% veća toplinska snaga, uz povećanje specifične potrošnje goriva. Istovremeno su se snaga, tj. zakretni moment motora, smanjili za približno 7%. Ostali parametri bitni za rad motora nisu se znatnije promijenili.

Prikazana simulacija pokazuje opravdanost pomaka SOI i EVO u svrhu dobivanja dovoljne dodatne toplinske energije koja se efikasno može iskoristiti u utilizacijskom procesu. Na taj način moguće je postići velike uštede u eksploataciji realnog brodskog dizelskog motora uz mogućnost ostvarivanja multikriterijalne optimizacije.



Slika 6.1: Toplina dostupna na izlazu iz turbine Q, kW ($n_{\rm M} = 118, 5 \text{ min}^{-1}$ i $x_{\rm reg} = 73 \text{ mm}$)



Slika 6.2: Specifična potrošnja goriva $b_{\rm e},~{\rm g/kWh}$ u ovisnosti
oSOIi $EVO~(n_{\rm M}=118,5$ min $^{-1}$ i
 $x_{\rm reg}=73~{\rm mm})$



Slika 6.3: Maksimalni tlak proces
a $p_{\rm max},~{\rm MPa}$ u ovisnosti oSOIi $EVO~(n_{\rm M}=118,5$ min $^{-1}$ i
 $x_{\rm reg}=73~{\rm mm})$



Slika 6.4: Maksimalna temperatura proces
a $T_{\rm max},~^{\circ}{\rm C}$ u ovisnosti oSOIi $EVO~(n_{\rm M}=118,5$ min $^{-1}$ i $x_{\rm reg}=73$ mm)



Slika 6.5: Zakretni moment na motoru $M_{\rm mot},~{\rm kNm}$ u ovisnosti
oSOIi $EVO~(n_{\rm M}=118,5$ min $^{-1}$ i
 $x_{\rm reg}=73$ mm)

6.2 Zadovoljavanje potrebne toplinske snage uz zadržavanje konstantnog zakretnog momenta i konstantne brzine vrtnje na motoru

U simulaciju se ušlo sa zadanim konstantnim zakretnim momentom motora, brzinom vrtnje motora i zadanom minimalnom toplinskom snagom iza turbine.

Radna točka zadana je preko brzine vrtnje motora $n = 118.5 \text{ min}^{-1}$ i potrebnog zakretnog momenta $M_{\rm M} = 465$ kNm. Zadana je i minimalna potrebna toplinska snaga iza turbine $Q_{min}=3200$ kW. Isto tako, zadani su limiti na ručicu između vrijednosti 40 i 75 mm. Najveća maksimalna temperatura u cilindru $T_{max,lim}=1900^{\circ}$ C i najveći dopušteni maksimalni tlak $p_{max,lim}=40$ MPa.

Početna ideja bila je pronaći radnu točku u kojoj su zadovoljeni svi zadani uvjeti. Za referentne postavke SOI i EVO nisu postignuti zadani moment niti toplinska snaga.

Da bi se postigla radna točka u kojoj su parametri jedanki ili najbliži mogući zadanima dopušten je pomak SOI i EVO.

U cilju postizanja i zadržavanja zakretnog momenta motora, pošto se on mijenja po pomacima kuteva *SOI* i *IVO*, potrebno je napraviti korekciju na ručici goriva. Položaj ručice limitiran je između minimalnog položaja od 40 i maksimalnog 75 mm.

Tek nakon ovog koraka motor je dostigao radnu točku u kojoj je zadovoljena potreba za zadanom toplinskom snagom. Isto tako, postignut je i zadani zakretni moment na motoru. U zadanoj rezoluciji pretraživanja zadovoljila je samo jedna točka. U slučaju da je više točaka zadovoljilo zadane uvjete simulacije, pristupilo bi se odabiru one koja ima najmanju specifičnu potrošnju goriva.

Na slici 6.6 vidljivo je polje zakretnog momenta motora. Posebno zanimljivo područje je pri velikim pomacima ubrizgavanja goriva na kasnije. U tom području moment strmo opada što u simulacijama rezultira divergencijom.

U tablici 6.2 prikazani su radni parametri u referentnim položajima pomaka i u pomacima kuteva u kojima su postignuti zadani uvjeti.

SOI	EVO	$M_{\rm M}$	b_{e}	x_{reg}	$P_{\rm ef}$	$T_{\rm max}$	$p_{\rm max}$	Q
°KV	°KV	kNm	g/kWh	mm	MW	°C	MPa	kW
0	0	457,7	165,7	55	5,68	1452,2	11,67	2984,4
4,5	-2,5	465	175,7	59	5,77	1404,6	10,28	3300,9

Tablica 6.2: Maksimiziranje toplinskog toka za zadani $n_{\rm M} = 118.5 \text{ min}^{-1}$ i $M_{\rm M} = 465 \text{ kNm}$

Prolazi se čitavo polje mogućih pomaka SOI i EVO, za svaku kombinaciju pomaka traži se položaj ručice goriva s kojim je zadovoljen zadani zakretni moment. Zatim se provjerava da li ta nova radna točka zadovoljava unaprijed zadanu minimalnu toplinsku snagu iza turbine. Ako zadovoljava, provjerava se da li je ta nova radna točka a ima manju specifičnu potrošnju od prethodne. Ako je najmanje jedna točka zadovoljila sve navedene uvjete, sustav ima rješenje. Na sljedećim slikama prikazano je polje vrijednosti za zakretni moment motora $M_{\rm M} =$

Uspoređivani su karakteristični parametri što je vidljivo na slikama 6.9, 6.8, 6.10 , 6.11 i 6.6.



Slika 6.6: Zakretni moment na motoru $M_{\rm M}$, kNm u ovisnosti o SOI i EVO (gotovo konstantan, ali u nekim kombinacija ne može se održati)



Slika 6.7: Pomak ručice goriva za održavanje momenta $x_{\rm xreg},$ mm $(n_{\rm M}=118,5$ min $^{-1}$ i $M_{\rm M}=465~{\rm KNm})$



Slika 6.8: Specifična potrošnja goriva $b_{\rm e},$ g/kW
h $(n_{\rm M}=118,5$ min $^{-1}$ i $M_{\rm M}=465$ KNm)



Slika 6.9: Toplina dostupna na izlazu iz turbine $Q,~{\rm kW}~(n_{\rm M}=118,5~{\rm min}^{-1}$ i $M_{\rm M}=465~{\rm KNm})$



Slika 6.10: Maksimalni tlak proces
a $p_{\rm max},\,$ MPa u ovisnosti oSOIiEVO
 $(n_{\rm M}=118,5$ min $^{-1}$ i $M_{\rm M}=465~{\rm KNm})$



Slika 6.11: Maksimalna temperatura proces
a $T_{\rm max},~^\circ{\rm C}$ u ovisnosti oSOIi $EVO~(n_{\rm M}=118,5$ min $^{-1}$ i $M_{\rm M}=465~{\rm KNm})$

6.3 Optimiranje rada motora za minimalnu emisiju dušikovih oksida

U morima ograničenih akvatorija nametnuta su ograničenja emisije štetnih plinova, posebice dušičnih oksida. Kako je pokazatelj intenziteta njihove emisije maksimalna temperatura procesa u cilindru motora istražena je mogućnost da se za željenu snagu motora i limitiranu maksimalnu temperaturu u cilindru motora iznađu parametri pri kojima postižemo minimalnu specifičnu potrošnju goriva. Na taj način dovodimo motor u područje optimalnoga rada za zadanu dopuštenu maksimalnu temperaturu procesa. U tablici na slici 6.12 su navedeni podaci za optimirane uvjete rada motora u dvije zadane točke obzirom na potrebnu snagu i brzinu vrtnje, te maksimalnu dopuštenu temperaturu procesa u cilindru motora. Za usporedbu su u istoj tablici dani podaci za specifičnu potrošnju goriva i maksimalnu temperaturu procesa za refrentno podešenje motora (kutevi početka ubrizgavanja goriva i otvaranja ispušnog ventila). Prva radna točka je na 93% opterećenja, druga na 75%. Rezultati optimizacije su pokazali da je referentna točka za opterećenje motora pri 93% ujedno i optimalna točka, dok za opterećenje 75% to nije slučaj. Zadane granice maksimalne temperature procesa postavljene su na 1600 °C pri 93% opterećenja i 1500 °C pri 75% opterećenja. Iz tablice se vidi da smo pri 75% opterećenja motora dobili temperaturu od 1477 °C uz 3,3% veću potrošnju goriva. Dobivena maksimalna temperatura je za 32 °C niža od one za referentne uvjete. Već i mala sniženja maksimalne temperature na tako visokim vrijednostima znače veliko smanjenje emisije dušikovih oksida.

Opterećenje, %	Snaga, KW	n _M , min-1	M _M , kNm	T _{max,limit} ^o C	SOI	EVO	b _e , g/kWh	Tmax	b _{e,ref} , g/kWh	Tmax,ref °C
93	7500	117,5	689,53	1600	0	0	173,25	1563	173,25	1563
75	6000	110	520,87	1500	-6	14,5	175,5	1477	170,06	1509

Slika 6.12: Rezultati optimizacije potrošnje goriva

Na ovome primjeru prikazana je još jedna mogućnost korištenja neuronske mreže u različitim zadacima optimizacije rada "inteligentnog" brodskog motora.

7 Zaključak

Izrada modela sa neuronskom mrežom iz simulacijskog modela radi postizanja određenih performansi, a i novih mogućnosti analize podataka koje je bi inače teško postigli, nije jednostavan zadatak. Ulazni podaci moraju biti unutar svih radnih režima motora, što za provođenje potrebnih proračuna iziskuje velike resurse u vremenu i računalnoj opremi. Isto tako za postizanje stacionarnog stanja prilikom mjerenja potrebno je postupno dovoditi motor u stacionarnu radnu točku, za što je potrebno određeno vrijeme i potrošnja goriva. To vrijeme kod numeričkih simulacija zna biti i višestruko duže. Za očitanje stacionarnog stanja kod simulacije potrebno je voditi motor kroz stanja koja su za neuronsku mrežu irelevantna. No jednom kad su traženi podaci dobiveni, a neuronska mreža optimirana, naučena i operativna, ona je u stanju gotovo 3000 puta brže dati tražene podatke karakteristika motora nego je to slučaj primjenom numeričkih simulacija.

Brzina rada neuronske mreže čini je pogodnom za brze proračune u iznalaženju optimalnih uvjeta po različitim kriterijima koje možemo proizvoljno nametati. Upravo ta multikriterijalnost optimizacija je velika prednost koju nudi neuronska mreža. Velike mogućnosti neuronske mreže kao alata za provođenje najrazličitijih zadataka optimizacija čini ju za sada nezamjenjivom i pogodno za implementaciju u inteligentne sustave regulacije i vođenja motora s unutarnjim izgaranjem. Ovim radom prikazan je samo dio mogućnosti primjene neuronske mreže. Daljnja istraživanja primjene neuronskih mreža u području eksploatacije motora s unutarnjim izgaranjem dovesti će do većih mogućnosti u kvaliteti i opsegu predviđanja takvih mreža.

U radu su prikazane neke od mogućnosti primjene neuronske mreže za predviđanje karakteristika "inteligentnog" brodskog dvotaktnog dizelskog motora nove generacije koji ima mogućnost elektrohidrauličkog upravljanja ubrizgavanjem goriva i otvaranja ispušnog ventila. Kod tih motora moguće je tijekom rada (bez zaustavljanja motora) mijenjati strategiju ubrizgavanja goriva i pogona ispušnog ventila, čime se značajno mogu mijenjati vanjske karakteristike motora. Sustav regulacije takvih motora je mnogo složeniji od sustava regulacije klasičnih motora, bez takvih mogućnosti promjene parametara rada. Razvijena neuronska mreža prikazana u ovom radu samo je jedan od brojnih primjera mogućnosti u predviđanju karakteristika motora temeljem promjene kuteva početka ubrizgavanja goriva i otvaranja ispušnog ventila. Ta ista neuronska mreža, prikazana u ovom radu, može poslužiti i kao platforma za optimalno vođenje "inteligentnih" brodskih motora.

Primjenom razvijene neuronske mreže na nekoliko primjera optimiranja parametara za postizanje različitih nametnutih uvjeta prikazan je dio mogućnosti koje pruža takva mreža.

Tijekom izrade ovog rada, autor se više puta susreo s problemom točnosti i pouzdanosti podataka za učenje mreže. Pri obradi tih podataka neuronska mreža je pokazala velike dijagnostičke mogućnosti za prepoznavanje problematičnih podataka.

U ovom radu istražene su promjene karakteristika "inteligentnog" brodskog dvotaktnog dizelskog motora samo za uvjete da se promjene kutovi početka ubrizgavanja goriva i početka otvaranja ispušnog ventila. Pritom se nisu mijenjale strategije ubrizgavanja goriva (tijek ubrizgavanja) i krivulja otvaranja ispušnog ventila, što je ostavljeno za buduća istraživanja. Već i ovdje provedena istraživanja ukazala su na veliki potencijal koji pruža elektrohidrauličko upravljanje ubrizgavanjem goriva i pogona ispušnog ventila na dovođenje suvremenog "inteligentnog" brodskog motora u željene uvjete rada.

Razvijeni model neuronske mreže u potpunosti je pripremljen za prihvat novih podataka izmjerenih tijekom eksploatacije motora. Prvim usporedbama izmjerenih podataka i podataka neuronske mreže moći će se ocjeniti kvaliteta izmjerenih podataka i cijelog mjernog sustava. Ta ocjena je preduvjet za kasnije analize mogućih odstupanja sustava od očekivanih normalnih stanja za potrebe dijagnostike nadolazećih kvarova.

Namjera prikazanih istraživanja bila je u izradi modela neuronskih mreža za implementaciju u suvremenim inteligentnim sustavima vođenja glavnog brodskog dizelskog motora.

Bibliografija

- [1] Radica, G. Ekspertni sustav za dijagnostiku stanja i optimiranje rada brodskog dieselovog motora. PhD thesis, 2008.
- [2] Mrakovčić, T. Osnivanje i vođenje brodskog pogonskog postrojenja primjenom numeričke simulacije. PhD thesis, 2003.
- [3] Senčić, T. Analiza mogućnosti smanjenja emisija čađe i NOx na suvremenim sporohodnim dizelskim dvotaktnim motorima. PhD thesis, 2010.
- [4] Antonić, R., Munitić, A., and Antonić, R. Umjetne neuronske mreže u obradi senzorskih signala brodskih dizelskih motora. *Naše more*, 1-2:21–29, 2003. Artificial Neural Networks in Sensors Signals Processing within Marine Diesel Engine Process.
- [5] Antonić, R. Na kvarove tolerantan sustav upravljanja sporohodnim dizelskim motorom za brodsku propulziju. PhD thesis, 2002.
- [6] Dovifaaz, X., Ouladsine, M., Rachid, A., and Bloch, G. Neural modeling and control of a diesel engine with pollution constraints. *Proceedings of the American Control Conference*, 2002.
- [7] Alonso, J. M., Alvarruiz, F., Desantes, J. M., Hernández, L., Hernández, V., and Moltó, G. Combining neural networks and genetic algorithms to predict and reduce diesel engine emissions. *IEEE transactions on evolutionary computation*, 11(1):46– 55, February 2007.
- [8] Arcaklioğlu, E. and İsmet Çelikten. A diesel engine's performance and exhaust emissions. *Applied Energy*, 80:11–22, 2005.
- [9] Tehranian, A. Effects of artificial neural networks characterization on prediction of diesel engine emissions. Master's thesis, 2003.
- [10] Bin, S., Fan-ming, Z., and Yu-tao, C. Control oriented real time model of marine powerstation diesel engine based on neural network. pages 386–390, 2011.
- [11] Brahma, I., He, Y., and Rutland, C. J. Improvement of neural network accuracy for engine simulations. SAE, 2003.
- [12] Zweiri, Y. H. and Seneviratne, L. D. Diesel engine indicated torque estimation based on artificial neural networks. *IEEE*, 2007.
- [13] Deng, J., Maass, B., and Stobart, R. Using artificial neural networks for representing the brake specific-fuel consumption and intake manifold pressure of a diesel engine. *IEEE*, 2009.
- [14] Zhou, J. and Xu, L. The fault diagnosis of marine engine cooling system based on artificial neural network (ann). *IEEE*, 2010.

- [15] Wang, J., Zhang, Y., Xiong, Q., and Ding, X. Nox prediction by cylinder pressure based on RBF neural network in diesel engine. *International Conference on Measuring Technology and Mechatronics Automation*, 2010.
- [16] He, Y. and Rutland, C. J. Modeling of a turbocharged di diesel engine using artificial neural networks. SAE Technical Paper, 2002.
- [17] He, Y. and Rutland, C. J. Neural cylinder model and its transient results. SAE Technical Paper, 2003.
- [18] Beuschel, M. Neuronale Netze zur Diagnose und Tilgung von Drehmomentschwingungen am Verbrennungsmotor. PhD thesis, 2000.
- [19] Brahma, I. and Rutland, C. J. Optimization of diesel engine operating parameters using neural networks. SAE Technical Paper, 2003.
- [20] Brzozowska, L., Brzozowski, K., and Nowakowski, J. An application of artificial neural network to diesel engine modelling. *IEEE*, 2005.
- [21] Butuk, N. Diesel engine emissions prediction using parallel neural networks. Technical report, 2004.
- [22] Chiao, S., Pan, Xufeng, and Xiaolei, L. The application of multisensor fusion technology in diesel engine oil analysis. 1996.
- [23] Cui, Y., Feng, X., Liu, L., Hou, T., and Liu, C. Research on active control of diesel engine based on wavelet neural network. *International Conference on Industrial Mechatronics and Automation*, 2009.
- [24] Gamo, S. O., Ouladsine, M., and Rachid, A. Diesel engine exhaust emissions modelling using artificial neural networks. SAE, 1999.
- [25] Gu, F., Jacob, P., and Ball, A. A RBF neural network model for cylinder pressure reconstruction in internal combustion engines. *IEEE*, 1996.
- [26] Hafner, M., Nelles, M. S. O., and Isermann, R. Fast neural networks for diesel engine control design. *Control Engineering Practice*, 8:1211–1221, 2000.
- [27] Hashemi, N. and Clark, N. N. Artificial neural network as a predictive tool for emissions from heavy-duty diesel vehicles in southern california. *International Journal* of Engine Research, 8(4):321–336, 2007.
- [28] He, Y. and Lin, C.-C. Development and validation of a mean value engine model for integrated engine and control system simulation. 2007.
- [29] Hiroyasu, T., Miki, M., Kamiura, J., Watanabe, S., and Hiroyasu, H. Multi-objective optimization of diesel engine emissions and fuel economy using genetic algorithms and phenomenological model. *SAE*, 2002.
- [30] Hošovský, A. and Boržíková, J. Emission model for optimization of combustion control using intelligent methods. *Journal of applied science in the thermodynamics* and fluid mechanics, 2, 2010.

- [31] Isermann, R. and Muller, N. Modeling and adaptive control of combustion engines with fast neural networks. *Eunite*, 2001.
- [32] Janakiraman, V. M., Suryanarayanan, S., Saravanan, S., and Rao, G. L. N. Analysis of the effect of in-cylinder parameters on nox and hc emissions of a ci engine using artificial neural networks. *SAE Technical Paper*, 2006.
- [33] Jarrett, R. P. and Clark, N. N. Weighting of parameters in artificial neural network prediction of heavy-duty diesel engine emissions. *SAE Technical Paper*, 2002.
- [34] Kesgin, U. Genetic algorithm and artificial neural network for engine optimisation of efficiency and nox emission. *Fuel*, 83:885–895, 2004.
- [35] Koprinkova, P. and Petrova, M. Data-scaling problems in neural-network training. Engineering Applications of Artificial Intelligence, 12:281–296, 1999.
- [36] Korres, D., Anastopoulos, G., Lois, E., Alexandridis, A., Sarimveis, H., and Bafas, G. A neural network approach to the prediction of diesel fuel lubricity. *Fuel*, 81:1243– 1250, 2002.
- [37] Leonhardt, S., Gao, N., and Kecman, V. Real time supervision of diesel engine injection with RBF-based neural networks. *Proceedings of the American Control Conference*, 1995.
- [38] Liu, Z. and Fei, S. Emissions prediction of cng/diesel dual fuel engine based on RBF neural network. SAE Technical Paper, 2004.
- [39] de Lucas, A., Duran, A., Carmona, M., and Lapuerta, M. Modeling diesel particulate emissions with neural networks. *Fuel*, 2001.
- [40] Maaß, B., Stobart, R., and Deng, J. Diesel engine emissions prediction using parallel neural networks. ACC'09 Proceedings of the 2009 conference on American Control Conference.
- [41] Mitsuhashi, K., Tsuchiya, T., Morishita, S., Shiraishi, T., and Sasaki, H. Revolution control for diesel engines by neural networks. SAE Technical Paper, 2004.
- [42] Murphy, B. J., Lebold, M. S., Reicbard, K., Galie, T., and Byington, C. Diagnostic fault detection for internal combustion engines via pressure curve reconstruction. 2003.
- [43] Nasr, G. E., Badr, E. A., and Joun, C. Backpropagation neural networks for modeling gasoline consumption. *Energy Conversion and Management*, 44:893–905, 2003.
- [44] Obodeh, O. and Ajuwa, C. I. Evaluation of artificial neural network performance in predicting diesel engine nox emissions. *European Journal of Scientific Research*, 33:642–653, 2009.
- [45] Omran, R., Younes, R., and Champoussin, J.-C. Optimal control of a variable geometry turbocharged diesel engine using neural networks: Applications on the etc test cycle. *IEEE*, 2009.

- [46] Ouladsine, M., Bloch, G., and Dovifaaz, X. Neural modeling and control of diesel engine with pollution constraints. *Journal of Intelligent and Robotic Systems*, 41:157–171, 2005.
- [47] Parlak, A., Islamoglu, Y., Yasar, H., and Egrisogut, A. Application of artificial neural network to predict specific fuel consumption and exhaust temperature for a diesel engine. *Applied Thermal Engineering*, 26:824–828, 2006.
- [48] Qiang, H., Fuyuan, Y., Ming, Z., and Minggao, O. Study on modeling method for common rail diesel engine calibration and optimization. SAE Technical Paper, 2004.
- [49] Shi, C., Guo, C., and Sun, C. Simulation and optimal control of diesel engine propulsion system. World Congress on Computer Science and Information Engineering, 2009.
- [50] Suryanarayanan, S., Janakiraman, V. M., and Rao, G. L. N. Ann analysis of performance characteristics of ci engine fuels based on physical and chemical properties and estimation of optimal blend of biodiesels with diesel. *SAE Technical Paper*, 2006.
- [51] Traver, M. L., Atkinson, R. J., and Atkinson, C. M. Neural network-based diesel engine emissions prediction using in-cylinder combustion pressure. *SAE Technical Paper*, 1999.
- [52] Valčić, M. Inteligentni sustavi nadzora i dijagnostike kvarova temeljeni na umjetnim neuronskim mrežama. *Pomorstvo*, 18:53–78, 2004.
- [53] Wang, S., Yu, D., Gomm, J., Page, G., and Douglas, S. Adaptive neural network model based predictive control for air-fuel ratio of si engines. 2006.
- [54] Wang, M., Zhang, J., Zhang, S., and Ma, Q. Predication emission of an intelligent marine diesel engine based on modeling of bp neural networks. *Sixth International Conference on Natural Computation*, 2010.
- [55] Wang, M., Zhang, J., Zhang, S., and Ma, Q. Predication emission of an marine two stroke diesel engine based on modeling of radial basis function neural networks. *Second WRI Global Congress on Intelligent Systems*, 2010.
- [56] Wu, B., Prucka, R. G., and Filipi, Z. S. Cam-phasing optimization using artificial neural networks as surrogate models—fuel consumption and nox emissions. *SAE Technical Paper*, 2006.
- [57] Xin, W., Hongliang, Y., and Lin, Z. Improved genetic algorithm and neural network method and the application in fault diagnosis of valve diesel engine. *IEEE*, 2010.
- [58] Xu, K., Xie, M., Tang, L., and Ho, S. Application of neural networks in forecasting engine systems reliability. *Applied Soft Computing*, 2:255–268, 2003.
- [59] Yu, L., Wang, S., and Lai, K. An integrated data preparation scheme for neural network data analysis. *IEEE*, 2006.
- [60] Pflaum, W. and Mollenhauer, K. Wärmübergang in der Verbrenungskraftmaschine. Springer Verlag, Wien, 1977.

- [61] Woschni, G. Die berechnung der wandverluste und thermischen belastung der bauteile von dieselmotoren. MTZ 31, 18 42:491–499, 1970.
- [62] Hohenberg, G. Advanced approaches for heat transfer calculation. *SAE Paper* 790825, 1979.
- [63] Heywood, J. Engine combustion modelling an overview. Symposium on Combustion Modelling, GMC REsearch Labs., 1980.
- [64] Boulochos, K. and Papadopulos, S. Zur modellbildung des motorischen verbrennungsablaufes. MTZ, 45(1):21–26, 1984.
- [65] Sitkei, G. Uber den dieselmotorischen zündverzug. MTZ, 24(6):190–194, 1963.
- [66] Betz, A. and Woschni, G. Umsetzungsgrad und brennverlauf aufgeladener dieselmotoren im instationaren betrieb. MTZ, 47(7/8):263–267, 1986.
- [67] Bošnjaković, F. Nauka o toplini II. Tehnička knjiga, Zagreb, 1976.
- [68] Chapman, K. Engine Airflow Algorithm Prediction, Introduction to Internal Combustion Engines. Kansas State University, 2001.
- [69] Grohe, H. Otto und Dieselmotoren, Arbeitweise, Aufbau und Berechnung von Zweitakt und Viertakt Motoren, volume 47. Vogel Verlag, 6. Auflage, Würtzburg, 1982.
- [70] Sher, E. and Harari, R. A. A simple and realistic model for the scavenging process in a cranckcased scavenged two-stroke cycle engine. J. of power and energy, 205:263– 267, 1991.
- [71] Dang, D. and Wallace, F. Some single zone scavenging models for two-stroke engines. Int. J. Mech. Sci., 34(8), 1992.
- [72] Blair, G. P. Design and simulation of two-stroke engines. SAE Publishing, Warrendale, 1996.
- [73] Gerstle, M. and Merker, G. P. Evaluation on two-stroke engines scavenging models. SAE Paper 970358 International Congress & Exposition, 1997.
- [74] Hopkins, B. The charging of two cycle internal combustion engines. Trans. NE Coast Inst. Engineers, 30, 1914.
- [75] Boy, P. Beitrag zur Berechnung des instationären Betriebsverhaltens mittelschnellaufenden Schiffsdieselmotoren. PhD thesis, 1980.
- [76] Bulaty, T. Special problems involved in the step by step calculation of the gas exchange process - typical applications. *ASME Publication*, 75-DGP-2, 1974.
- [77] Medica, V. Simulacija dinamičkih uvjeta rada dizelmotora sa prednabijanjem kod pogona električnog generatora. PhD thesis, 1998.
- [78] A/S, M. D. The man b&w engine vit fuel pump. Technical Papers, Copenhagen, Denmark, 2004.

- [79] Benson, R. S., Ledger, J. D., and Whitehouse, N. D. Dynamic modeling of a turbocharged diesel engine. J. of Mech. Eng. 1-12, 1973.
- [80] Vogel, W. Simulation von einspritzvorgängen auf einem digitalen kleinrechner. *MTZ*, 35(9):282–286, 1974.
- [81] Taylor, B. J. Methods and Procedures for the Verification and Validation of Artificial Neural Networks. Springer Science+Business Media, Inc, 2006.
- [82] Račić, N. Simulacija rada brodskog propulzijskog sustava sa sporohodnim dizelskim motorom u otežanim uvjetima. PhD thesis, 2008.

Popis oznaka i simbola

SIMBOL	JEDINICA	NAZIV
A	m^2	površina
$b_{ m e}$	g/kWh	specifična potrošnja goriva
$c_{ m m}$	m/s	srednja stapna brzina
c_0	m/s	teoretska brzina strujanja
$c_{\rm p}$	J/(kg K)	specifični toplinski kapacitet pri $\ \mathbf{p}=\mathrm{const}$
d	m	promjer
E	J	energija
EVO	o	kut pomaka otvaranja ispušnih ventila
F	Ν	sila
h	J/kg	specifična entalpija
h	m	podizaj, hod ventila, visina
$H_{\rm d}$	J/kg	donja ogrjevna moć goriva
J	$\rm kg~m^2$	moment tromosti
$K_{\rm p}$	-	faktor proporcionalnosti
k	W/m	toplinska vodljivost
l	m	duljina ojnice
L	m	dužina
$L_{\rm st}$	kg	masa zraka za stehiometrijsko izgaranje go- riva
m	kg	masa
m	-	Vibeov eksponent
\dot{m}	$\rm kg/s$	maseni protok
M	Nm	moment
n	\min^{-1}	brzina vrtnje
p	Pa	tlak
Р	W	snaga
Pr	-	Prantlov broj

q	W/kg	specifični toplinski tok
Q	J	toplina
Q	m^3/s	protok
r	m	polumjer koljenastog vratila
R	J/(kg K)	plinska konstanta
Re	-	Reynoldsov broj
SOI	0	kut pomaka početka ubrizgavanja goriva
t	S	vrijeme
t	°C	temperatura
T	Κ	temperatura
u	J/kg	specifična unutarnja energija
u	m/s	obodna brzina
U	J	unutarnja energija
v	m/s	brzina
V	m^3	volumen
V_0	m^3	volumen kompresijskog prostora
$V_{ m S}$	m^3	stapajni volumen
w	-	težinski koeficijent
W	J	rad
W	J/(s K)	toplinski kapacitet
x	m	hod klipa, hod ručice regulatora
x	-	broj ulaza u neuron
y	-	izlaz iz neurona
z	-	broj cilindara motora

O. Bukovac, Doktorska disertacija

Grčka slova

JEDINICA	NAZIV
$W/(m^2 \cdot K)$	koeficijent prijelaza topline
-	koeficijent protoka
-	stupanj čistoće plinova
o	kut između ojnice i osi cilindra
-	geometrijski stupanj kompersije
-	stupanj djelovanja
Ns/m^2	dinamička viskoznost
_	stupanj punjenja
-	potpunost ispiranja
o	kut zakreta osnog koljena
-	eksponent adijabate
-	pretičak zraka
W/(m K)	toplinska vodljivost
-	omjer r/l polužja koljenastog mehanizma
-	stupanj dobave
-	faktor trenja
-	bezdimenzijska značajka brzine
-	omjer tlakova
$ m kg/m^3$	gustoća
-	taktnost motora (2 ili 4)
-	funkcija protjecanja
	JEDINICA W/(m ² ·K) - - Ns/m ² - - W/(m K) - - - Kg/m ³ - -

Indeksi

INDEKS TUMAČENJE

0	nazivna veličina
atm	atmosfera
с	cilindar
cjg	cjevovod goriva
dz	dodatni zrak
ef	efektivno
g	gorivo
geom	geometrijski
ΗZ	hladnjak zraka
i, izl	izlaz
i	ispuh, ispušni sistem, indeks
Ikan	ispušni kanal
IK	ispušni kolektor
ind	indicirani
IV	ispušni ventil
izg	izgaranje
izl	izlaz
j	indeks
k	klip, indeks neurona
m	koljenasti mehanizam
М	motor
max	maksimalni
meh	mehanički
min	minimalni
nP	nakon puhala
nT	nakon turbine
р	ukupni broj ulaza u neuron, indeks
Р	puhalo
PI	početak izgaranja
PD	početak dobave goriva

Pot	potrošač
pР	prije puhala
pr	proces, propušteno
prot	protok
рТ	prije turbine
PU	početak ubrizgavanja
R	regulator
RB	granična Bosch vrijednost za čađenje motora
reg	regulator
RV	rashladna voda
S	adijabatski
sp	svježe punjenje
sr	srednji
st	stijenka
Т	turbina
teo	teoretski
TI	trajanje izgaranja
TP	turbopuhalo
tr	trenje
u	unutarnji, usis, ulaz
uk	ukupno
UK	usisni kolektor
Ukan	usisni kanal
UV	usisni ventil
UZ	usis zatvoren
V	ventil
vol	volumetrijski
ZP	zakašnjenje paljenja
zpi	zaostali plinovi izgaranja
zr	zrak

Popis slika

3.1	Shema dizelskog motora s prednabijanjem [2]	$\overline{7}$
3.2	Kontrolni volumen cilindra motora [2]	10
3.3	Udio izgorenog goriva i brzina izgaranja prema Vibeu	14
3.4	Model potpunog miješanja	19
3.5	Promjena potpunosti ispiranja, odstupnja punjenja i čistoće plinova u ovis-	
	nosti o stupnju dobave	20
3.6	Usisni kolektor $[2]$	20
3.7	Bezdimenzijska promjena temperature zraka za unakrsni izmjenjivač topline	23
3.8	Ispušni kolektor [2]	23
3.9	Turbopuhalo	25
3.10	Polje karakteristika radijalne turbine na ispušne plinove	26
3.11	Polje karakteristika aksijalne turbine na ispušne plinove	26
3.12	Polje karakteristika puhala	27
3.13	Visokotlačna pumpa goriva s VIT sustavom sporohodnog brodskog motora	
	[78]	32
3.14	Djelovanje visokotlačne pumpe goriva s VIT funkcijom	33
3.15	Općenite karakteristike visokotlačne pumpe goriva	33
3.16	Dijagram toka informacija za model brodskog dizelskog motoras predna-	
	bijanjem [2] \ldots	34
3.17	Proces izrade simulacijskog modela	36
3.18	Blok-shema modela brodskog propulzijskog sustava izvedena u Matlab-	
	Simulink računalnoj aplikaciji	37
11		
	Prikaz naurona ga pragom	11
4.1	Prikaz neurona sa pragom	41 42
4.1 4.2 4.3	Prikaz neurona sa pragom	41 42 43
4.1 4.2 4.3	Prikaz neurona sa pragom	41 42 43 43
4.1 4.2 4.3 4.4 4.5	Prikaz neurona sa pragom	41 42 43 43
4.1 4.2 4.3 4.4 4.5 4.6	Prikaz neurona sa pragom	41 42 43 43 44 44
$\begin{array}{c} 4.1 \\ 4.2 \\ 4.3 \\ 4.4 \\ 4.5 \\ 4.6 \\ 4.7 \end{array}$	Prikaz neurona sa pragom	41 42 43 43 44 44 45
$\begin{array}{c} 4.1 \\ 4.2 \\ 4.3 \\ 4.4 \\ 4.5 \\ 4.6 \\ 4.7 \\ 4.8 \end{array}$	Prikaz neurona sa pragom	41 42 43 43 44 44 45 45
4.1 4.2 4.3 4.4 4.5 4.6 4.7 4.8 4.9	Prikaz neurona sa pragom	$\begin{array}{c} 41 \\ 42 \\ 43 \\ 43 \\ 44 \\ 44 \\ 45 \\ 45 \\ 46 \end{array}$
$\begin{array}{c} 4.1 \\ 4.2 \\ 4.3 \\ 4.4 \\ 4.5 \\ 4.6 \\ 4.7 \\ 4.8 \\ 4.9 \\ 4.10 \end{array}$	Prikaz neurona sa pragom Prikaz neurona sa dodatnom težinom umjesto praga Prikaz neurona sa dodatnom težinom umjesto praga Logistička sigmoidna funkcija Simetrična logistička sigmoidna funkcija Simetrična logistička sigmoidna funkcija Stepenasta sigmoidna funkcija Simetrična stepenasta sigmoidna funkcija Simetrična stepenasta sigmoidna funkcija Linearna funkcija Simetrična funkcija Simetrična funkcija Simetrična funkcija Limetrična funkcija Simetrična funkcija Simetrična funkcija Simetrična funkcija Limitirana linearna funkcija Simetrična funkcija Simetrična funkcija Simetrična funkcija	$\begin{array}{c} 41 \\ 42 \\ 43 \\ 43 \\ 44 \\ 45 \\ 45 \\ 45 \\ 46 \\ 46 \end{array}$
$\begin{array}{c} 4.1 \\ 4.2 \\ 4.3 \\ 4.4 \\ 4.5 \\ 4.6 \\ 4.7 \\ 4.8 \\ 4.9 \\ 4.10 \\ 4.11 \end{array}$	Prikaz neurona sa pragom Prikaz neurona sa dodatnom težinom umjesto praga Prikaz neurona sa dodatnom težinom umjesto praga Logistička sigmoidna funkcija Simetrična logistička sigmoidna funkcija Simetrična logistička sigmoidna funkcija Stepenasta sigmoidna funkcija Simetrična stepenasta sigmoidna funkcija Simetrična stepenasta sigmoidna funkcija Linearna funkcija Simetrična funkcija Simetrična funkcija Simetrična funkcija Simetrična funkcija praga Simetrična funkcija praga Simetrična funkcija Simetrična funkcija Simetrična linearna funkcija Simetrična funkcija Simetrična funkcija Simetrična funkcija	$\begin{array}{c} 41 \\ 42 \\ 43 \\ 43 \\ 44 \\ 44 \\ 45 \\ 45 \\ 46 \\ 46 \\ 47 \end{array}$
4.1 4.2 4.3 4.4 4.5 4.6 4.7 4.8 4.9 4.10 4.11 4.12	Prikaz neurona sa pragom	$\begin{array}{c} 41 \\ 42 \\ 43 \\ 43 \\ 44 \\ 45 \\ 45 \\ 45 \\ 46 \\ 46 \\ 47 \\ 47 \end{array}$
$\begin{array}{c} 4.1 \\ 4.2 \\ 4.3 \\ 4.4 \\ 4.5 \\ 4.6 \\ 4.7 \\ 4.8 \\ 4.9 \\ 4.10 \\ 4.11 \\ 4.12 \\ 4.13 \end{array}$	Prikaz neurona sa pragom	$\begin{array}{c} 41 \\ 42 \\ 43 \\ 43 \\ 44 \\ 45 \\ 45 \\ 45 \\ 46 \\ 46 \\ 47 \\ 47 \\ 48 \end{array}$
$\begin{array}{c} 4.1 \\ 4.2 \\ 4.3 \\ 4.4 \\ 4.5 \\ 4.6 \\ 4.7 \\ 4.8 \\ 4.9 \\ 4.10 \\ 4.11 \\ 4.12 \\ 4.13 \\ 4.14 \end{array}$	Prikaz neurona sa pragom	$\begin{array}{c} 41 \\ 42 \\ 43 \\ 43 \\ 44 \\ 44 \\ 45 \\ 45 \\ 46 \\ 46 \\ 47 \\ 47 \\ 48 \\ 48 \\ 48 \end{array}$
$\begin{array}{c} 4.1 \\ 4.2 \\ 4.3 \\ 4.4 \\ 4.5 \\ 4.6 \\ 4.7 \\ 4.8 \\ 4.9 \\ 4.10 \\ 4.11 \\ 4.12 \\ 4.13 \\ 4.14 \\ 4.15 \end{array}$	Prikaz neurona sa pragom	$\begin{array}{c} 41 \\ 42 \\ 43 \\ 43 \\ 44 \\ 45 \\ 45 \\ 46 \\ 46 \\ 47 \\ 48 \\ 48 \\ 48 \\ 49 \end{array}$
$\begin{array}{c} 4.1 \\ 4.2 \\ 4.3 \\ 4.4 \\ 4.5 \\ 4.6 \\ 4.7 \\ 4.8 \\ 4.9 \\ 4.10 \\ 4.11 \\ 4.12 \\ 4.13 \\ 4.14 \\ 4.15 \\ 4.16 \end{array}$	Prikaz neurona sa pragom	$\begin{array}{c} 41 \\ 42 \\ 43 \\ 43 \\ 44 \\ 45 \\ 45 \\ 46 \\ 46 \\ 47 \\ 48 \\ 48 \\ 49 \\ 49 \\ 49 \end{array}$
$\begin{array}{c} 4.1 \\ 4.2 \\ 4.3 \\ 4.4 \\ 4.5 \\ 4.6 \\ 4.7 \\ 4.8 \\ 4.9 \\ 4.10 \\ 4.11 \\ 4.12 \\ 4.13 \\ 4.14 \\ 4.15 \\ 4.16 \\ 4.17 \end{array}$	Prikaz neurona sa pragom	$\begin{array}{c} 41 \\ 42 \\ 43 \\ 44 \\ 45 \\ 45 \\ 46 \\ 46 \\ 47 \\ 47 \\ 48 \\ 48 \\ 49 \\ 49 \\ 51 \end{array}$
$\begin{array}{c} 4.1\\ 4.2\\ 4.3\\ 4.4\\ 4.5\\ 4.6\\ 4.7\\ 4.8\\ 4.9\\ 4.10\\ 4.11\\ 4.12\\ 4.13\\ 4.14\\ 4.15\\ 4.16\\ 4.17\\ 4.18\end{array}$	Prikaz neurona sa pragom	$\begin{array}{c} 41 \\ 42 \\ 43 \\ 44 \\ 45 \\ 45 \\ 45 \\ 46 \\ 46 \\ 47 \\ 48 \\ 48 \\ 49 \\ 51 \\ 54 \end{array}$
$\begin{array}{c} 4.1 \\ 4.2 \\ 4.3 \\ 4.4 \\ 4.5 \\ 4.6 \\ 4.7 \\ 4.8 \\ 4.9 \\ 4.10 \\ 4.11 \\ 4.12 \\ 4.13 \\ 4.14 \\ 4.15 \\ 4.16 \\ 4.17 \\ 4.18 \end{array}$	Prikaz neurona sa pragom	$\begin{array}{c} 41 \\ 42 \\ 43 \\ 44 \\ 45 \\ 45 \\ 46 \\ 46 \\ 47 \\ 47 \\ 48 \\ 48 \\ 49 \\ 51 \\ 54 \end{array}$

5.2	Usporedba izmjerenih vrijednosti i rezultata simulacije u stacionarnim	
	točkama, pri: 25%, 50%, 75%, 93,5%, 100% i 110% opterećenja motora	
	[82]	59
5.3	Histogrami ulaznih podataka u simulacijama	63
5.4	Histogrami ulaznih simulacijskih podataka, konvergirajući	64
5.5	Histogrami ulaznih simulacijskih podataka, divergirajući	65
5.6	Histogrami ulaznih podataka za treniranje mreže	66
5.7	Histogrami ulaznih podataka za validaciju mreže	67
5.8	Histogrami ulaznih podataka za konačni test mreže (ocjenu nakon treniranja)	68
5.9	Specifična potrošnja goriva, usporedba simulacije i neuronske mreže	70
5.10	Zakretni moment na motoru, usporedba simulacije i neuronske mreže	71
5.11	Brzina vrtnje turbopuhala, usporedba simulacije i neuronske mreže	72
5.12	Maseni protok na puhalu, usporedba simulacije i neuronske mreže	73
5.13	Maseni protok na turbini, usporedba simulacije i neuronske mreže	74
5.14	Tlak u usisnom kolektoru, uspored ba simulacije i neuronske mreže $\ . \ . \ .$	75
5.15	Tlak u ispušnom kolektoru, uspored ba simulacije i neuronske mreže $\ . \ .$	76
5.16	Temperatura u ispušnom kolektoru, uspored ba simulacije i neuronske mreže $% \left({{{\rm{T}}_{{\rm{s}}}}} \right)$	77
5.17	Temperatura u usisnom kolektoru, usporedba simulacije i neuronske mreže	78
5.18	Maksimalni tlak procesa, usporedba simulacije i neuronske mreže . . .	79
5.19	Temperatura na izlazu iz turbine, usporedba simulacije i neuronske mreže	80
5.20	Maksimalna temperatura procesa, usporedba simulacije i neuronske mreže	81
5.21	Podaci mjerenja na ispitnom stolu [82]	82
5.22	Zakretni moment motora $M_{\rm M}$, kNm $\ldots \ldots \ldots \ldots \ldots \ldots \ldots \ldots \ldots$	83
5.23	Snaga motora P_{ef} , MW;	83
5.24	Specifična potrošnja goriva $b_{\rm e}$, g/kWh	84
5.25	Tlak u ispušnom kolektoru $P_{\rm IK}$, MPa	84
5.26	Temperatura u ispušnom kolektoru $T_{\rm IK}$, °C $\ldots \ldots \ldots \ldots \ldots \ldots \ldots$	85
5.27	Brzina vrtnje turbopuhala $n_{\rm TP}/1000, \ {\rm min}^{-1}$	85
5.28	Temperatura iza turbine turbopuhala $T_{izl,T}$, °C	86
5.29	Maseni protok na turbini $m_{\text{prot},T}$, kg/s	87
5.30	Toplinska snaga ispušnih plinova na izlazu iz turbine Q, kW \ldots	87
5.31	Tlak u usisnom kolektoru $P_{\rm UK}$, MPa	88
5.32	Temperatura u usisnom kolektoru $T_{\rm UK}$, °C	88
5.33	Maksimalni tlak u cilindru motora p_{max} , MPa $\ldots \ldots \ldots \ldots \ldots \ldots$	89
5.34	Maksimalna temperatura u cilindru motora T_{max} , °C	89
5.35	Snaga motora P_{ef} , MW;	90
5.36	Specifična potrošnja goriva $b_{\rm e}$, g/kWh	91
5.37	Maseni protok na turbini $m_{\text{prot},T}$, kg/s	91
5.38	Temperatura ispušnih plinova iza turbine $T_{izl,T}$, °C	92
5.39	Toplinska snaga ispušnih plinova na izlazu iz turbine Q , kW	92
5.40	Maksimalni tlak u cilindru motora p_{max} , MPa $\ldots \ldots \ldots \ldots \ldots \ldots$	93
5.41	Maksimalna temperatura u cilindru motora T_{max} , °C	93
6.1	Toplina dostupna na izlazu iz turbine Q , kW ($n_{\rm M} = 118, 5 \min^{-1} i x_{\rm reg} = 72 \text{ mm}$)	0.0
6 9	(∂ IIIII)	90
0.2	specificna potrosnja goriva $\theta_{\rm e}$, g/kvvn u ovisnosti o SOI i EVO ($n_{\rm M} =$ 118.5 min $^{-1}$ i $x_{\rm e} = 73$ mm)	90
	$110,0 \text{ mm} 1 u_{\text{reg}} = 10 \text{ mm} \dots \dots \dots \dots \dots \dots \dots \dots \dots $	90

6.3	Maksimalni tlak procesa p_{max} , MPa u ovisnosti o SOI i EVO ($n_{\text{M}} = 118, 5$	
	min ⁻¹ i $x_{reg} = 73$ mm)	97
6.4	Maksimalna temperatura procesa T_{max} , °C u ovisnosti o SOI i EVO	
	$(n_{\rm M} = 118, 5 \text{ min}^{-1} \text{ i } x_{\rm reg} = 73 \text{ mm})$	97
6.5	Zakretni moment na motoru $M_{\rm mot}$, kNm u ovisnosti o SOI i EVO ($n_{\rm M} =$	
	118,5 min ⁻¹ i $x_{reg} = 73$ mm)	98
6.6	Zakretni moment na motoru $M_{\rm M}$, kNm u ovisnosti o SOI i EVO (gotovo	
	konstantan, ali u nekim kombinacija ne može se održati)	100
6.7	Pomak ručice goriva za održavanje momenta $x_{\rm xreg}$, mm ($n_{\rm M} = 118, 5$ min	
	$^{-1}$ i $M_{\rm M} = 465$ KNm)	100
6.8	Specifična potrošnja goriva $b_{\rm e}$, g/kWh ($n_{\rm M} = 118,5$ min $^{-1}$ i $M_{\rm M} = 465$	
	KNm)	101
6.9	Toplina dostupna na izlazu iz turbine Q , kW ($n_{\rm M} = 118, 5 \text{ min}^{-1}$ i $M_{\rm M} =$	
	465 KNm)	101
6.10	Maksimalni tlak procesa p_{max} , MPa u ovisnosti o SOI i EVO ($n_{\text{M}} = 118, 5$	
	min ⁻¹ i $M_{\rm M} = 465 \text{ KNm}$)	102
6.11	Maksimalna temperatura procesa $T_{\rm max}$, °C u ovisnosti o SOI i EVO	
	$(n_{\rm M} = 118, 5 \text{ min}^{-1} \text{ i } M_{\rm M} = 465 \text{ KNm}) \dots \dots \dots \dots \dots \dots \dots \dots \dots$	102
6.12	Rezultati optimizacije potrošnje goriva	103

Popis tablica

$5.1 \\ 5.2 \\ 5.3$	Osnovni podaci analiziranog motora 6S50MC MAN&BW [82] Vrijednosti ulaznih parametara	57 61 62
$6.1 \\ 6.2$	Maksimiziranje toplinskog toka za zadani $n_{\rm M} = 118.5$ i $x_{\rm reg} = 73$ Maksimiziranje toplinskog toka za zadani $n_{\rm M} = 118.5$ min ⁻¹ i $M_{\rm M} = 465$	95
	kNm	99

Životopis

Ozren Bukovac rođen je 13. ožujka 1978. godine u Rijeci, Republici Hrvatskoj. Osnovno je obrazovanje stekao u Rijeci, gdje je 1996. završio srednju Prvu sušačku hrvatsku gimanziju, prirodoslovno-matematički smjer. Godine 1996. upisuje se na sveulilišni studij strojarstva Tehničkog fakulteta Sveučilišta u Rijeci. Diplomirao je 2002. godine sa temom diplomskog rada "Analiza strujanja zraka u elektrostatskom precipitatoru termoelektrane Plomin 1".

Nakon studija radio je 2003. godine u poduzeću StudioArs d.o.o., Rijeka gdje se bavi programiranjem softverskih modula za aplikacije Hydra i Canalis. Od 2005. godine zaposlio se u poduzeću Dynomax d.o.o., Rijeka, na projektiranju vretena i konektora te razradi tehničke dokumentacije. U periodu od 2005. do 2006. zaposlen je u poduzeću ESCAD Konstrukcije d.o.o., Zadar, gdje radi na poslovima projektiranja alata za izradu karoserija automobila.

Godine 2006. zapošljava se kao znanstveni novak na znanstvenom projektu "Numeričke simulacije i optimizacija brodskih dizelskih motora", te iste godine upisuje poslijediplomski znanstveni studij na Tehničkom fakultetu Sveučilišta u Rijeci, smjer Termoenergetika. Održava auditorne i konstrukcijske vježbe iz predmeta sveučilišnog i stručnoga dodiplomskog studija strojarstva i brodogradnje: Toplinski strojevi i uređaji, Termodinamika, Brodski pogonski strojevi, Pogonski i radni strojevi i Motori.

Autor je i koautor na ukupno 10 objavljenih znanstvenih radova.

Govori i piše engleski jezik, a služi se njemačkim i talijanskim jezikom.