

Predviđanje parametara rada brodskog dizelskog motora primjenom neuronskih mreža

Bukovac, Ozren

Doctoral thesis / Disertacija

2012

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Rijeka, Faculty of Engineering / Sveučilište u Rijeci, Tehnički fakultet**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:188:414703>

Rights / Prava: [Attribution-NonCommercial 4.0 International/Imenovanje-Nekomercijalno 4.0 međunarodna](#)

Download date / Datum preuzimanja: **2025-01-26**



Repository / Repozitorij:

[Repository of the University of Rijeka Library - SVKRI Repository](#)



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).



Dekan

Prof. dr. sc. 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

U usporedbi s drugim strojevima za pogon broda dvotaktni sporohodni 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 ispušnih ventila. Kod tih "inteligentnih" motora moguće je tijekom rada (bez zaustavljanja motora) mijenjati strategiju ubrizgavanja goriva i pogona ispušnog ventila, čime se značajno mogu mijenjati vanjske karakteristike motora. Uvjeti proizvođača motora, nužni za pouzdanost rada i priznavanje garantnih uvjeta, koji definiraju strategiju gradijenta 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. Uz to što omogućuju bolji uvid u različite aspekte rada motora, daju i dodatne informacije iz ograničeno dostupnih eksperimentalnih podataka.

U ovoj disertaciji provedene su numeričke simulacije za izračunavanje stacionarnih stanja rada motora. U simulaciji se motor se postupno dovodi u stacionarnu radnu točku za što je potrebno određeno vrijeme koje zna biti i višestruko duže nego kod stvarnog rada motora.

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. Izrada modela s neuronskom mrežom iz simulacijskog modela radi postizanja određenih performansi, a i novih mogućnosti analize podataka koje je bi inače teško postigli, nije jednostavan zadatak. Pri obradi podataka neuronska mreža je pokazala velike dijagnostičke mogućnosti za prepoznavanje problematičnih podataka.

Odabrana neuronska mreža zadovoljila je unaprijed zadanu točnost i spremna je za prihvrat budućih eksperimentalnih podataka i njihovu obradu. Razvijeni model neuronske mreže u stanju je dati tražene podatke karakteristika motora više od 3000 puta u kraćem vremenu nego numeričke simulacije za zadanu stacionarnu radnu točku. Brzina rada neuronske mreže čini je pogodnom za brze proračune u iznalaženju optimalnih uvjeta po različitim kriterijima koje možemo proizvoljno nametati.

U radu se istražuje efikasno predviđanje radnih parametara u svrhu optimalnog upravljanja. Istražena je i mogućnost da se izlazni rezultati naučenih neuronskih mreža koriste kao ulazni podaci za optimizaciju traženih radnih uvjeta. Isto tako istraživanje pokazuje značajan utjecaj turbopuhala na rad motora. 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 u radne uvjete za potrebe utilizacije otpadne topline, uz minimalnu specifičnu potrošnju goriva na motoru, te za optimizaciju maksimalne temperature procesa motora u svrhu smanjenja emisija NO_x -a.

Ovim istraživanjem razvijen je model, baziran na neuronskim mrežama, koji omogućuje predviđanje parametara rada brodskog dizelskog motora. Namjera prikazanih istraživanja bila je u izradi modela neuronskih mreža za implementaciju u suvremenim

inteligentnim sustavima vođenja glavnog brodskog dizelskog motora. Razvijeni model neuronske mreže u potpunosti je pripremljen za prihvatanje novih podataka izmjerenih tijekom eksploatacije motora. Prvim usporedbama izmjerenih podataka i podataka neuronske mreže moći će se ocijeniti 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.

Abstract

Compared to the other machines for ship propulsion, two-stroke low speed diesel engines with supercharging have advantages due to its high efficiency and reliability. Modern low speed marine diesel engines have a lot of flexibility in operation due to the variable fuel injection strategy and management of the exhaust valve. During operation in these "intelligent" engine it is possible to change the strategy of the fuel injection and exhaust valve operation (without stopping the engine), which can significantly change the external characteristics of the engine. Terms of engine manufacturers, necessary for the reliable operation and recognition of warranty conditions which define the policy gradient of loading and running the engine, were built into the regulation and protection system of the engine.

Models for the engine numerical simulations are able to very reliably predict characteristics and behaviour of the engine in a variety of operating conditions. They provide greater insight into the various aspects of engine operation and additional information from limited available experimental data.

This dissertation carried out numerical simulations to calculate the stationary operation states. In the simulations, engine was gradually led to steady state operating point. This takes some time and can be several times longer than the actual operation.

The results of numerical simulations for heavy duty marine diesel engines were applied to select the type and structure of the neural network that is used in this paper, also for its learning and validation. It is not an easy task to develop neural network models with used simulation model in order to achieve certain performance and new opportunities to analyse data that would otherwise be difficult to achieve. Neural network data processing has shown diagnostic capabilities to identify problematic data.

Selected neural network satisfy the required accuracy and is ready to accept future experimental data and their analysis. Developed neural network model is able to provide the required engine data characteristics more than 3000 times faster than the numerical simulations for a given stationary operating point.

This paper explores efficient prediction of operating parameters for optimal control and the possibility that the outputs of learned neural networks are used as input data required for operating conditions optimization. Also, research shows that turbochargers have a significant effect on the engine performance. The dissertation presents examples of the neural networks application to optimize the potential of modern marine diesel engines, with the aim of achieving the required exhaust gases heat flow for waste heat utilization in the working conditions. As well, minimization of the engine specific fuel consumption, and optimization of the maximum process temperature to reduce emissions of NO_x's.

This research developed a model, based on neural networks, in order to predict the operating parameters of marine diesel engines. The intention was to develop the neural network model for implementation in intelligent systems running modern main ship diesel engines. The developed neural network model is fully prepared to accept new data measured during engine operation. After first comparison between measured data and the

neural network results it will be possible to estimate the quality of measured data and the entire measurement system. This estimation is a prerequisite for the subsequent analysis of possible deviations from the expected normal situation for diagnostic upcoming failures.

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	Uvod	1
1.1	Sporohodni brodski dizelski motori	1
1.2	Cilj istraživanja	2
1.3	Obrazloženje radne hipoteze	3
1.4	Struktura rada	3
2	Prethodna istraživanja	5
3	Matematički model dizelskog motora	7
3.1	Jednadžbe očuvanja mase i energije	8
3.2	Cilindar motora	9
3.2.1	Prijelaz topline u cilindru	11
3.2.2	Propuštanje radnog medija	11
3.2.3	Kompresija i ekspanzija	12
3.2.4	Izgaranje	12
3.2.5	Zakašnjenje paljenja	14
3.2.6	Potpunost izgaranja	14
3.2.7	Izmjena radnog medija kod četverotaktnog motora	16
3.2.8	Izmjena radnog medija kod dvotaktnog motora	17
	3.2.8.1 Način ispiranja cilindra velikih brodskih dvotaktnih motora	18
	3.2.8.2 Modeli izmjene radnog medija	18
	3.2.8.3 Model potpunog miješanja	19
3.3	Usisni kolektor	20
	3.3.1 Prijelaz topline u usisnom kolektoru	21
	3.3.2 Hladnjak zraka	22
3.4	Ispušni kolektor	23
	3.4.1 Prijelaz topline u ispušnom kolektoru	24
3.5	Turbopuhalo	24
	3.5.1 Turbina na ispušne plinove	25
	3.5.2 Puhalo	25
	3.5.3 Dinamika turbopuhala	27
3.6	Dinamika motornog mehanizma	28
3.7	Regulator	29
3.8	Visokotlačna pumpa goriva	31
3.9	Sustav dizelskog motora	33
3.10	Računalno simulacijski model brodskog propulzijskog sustava sa sporohodnim dvotaktnim dizelskim motorom	35
4	Model neuronske mreže	39
4.1	Uvod	39
4.2	Umjetni neuron	41
4.3	Aktivacijske funkcije	42
	4.3.1 Logistička sigmoidna funkcija	42

4.3.2	Funkcija hiperboličkog tangensa	44
4.3.3	Linearna funkcija	44
4.3.4	Funkcija praga	44
4.3.5	Limitirana linearna funkcija	45
4.3.6	Elliot funkcija	46
4.3.7	Gaussova funkcija	46
4.4	Modeliranje s umjetnom MLP neuronskom mrežom	47
4.5	Pristup modeliranju	48
4.5.1	Preprocesiranje podataka	48
4.5.1.1	Prikupljanje podataka	48
4.5.1.2	Ocjena i odabir podataka, ulazne i izlazne vrijednosti	49
4.5.1.3	Priprema skupa podataka za treniranje, validaciju i testiranje	50
4.5.1.4	Skaliranje i transformacija podataka	50
4.5.2	Odabir broja skrivenih slojeva i neurona u svakom sloju	51
4.5.3	Odabir inicijalnih težinskih vrijednosti	51
4.5.4	Proces učenja	52
4.5.5	Analiza rezultata mreže	53
4.5.6	Optimizacija strukture MLP mreže	53
5	Modeliranje neuronske mreže na simulacijskom modelu brodskog dizelskog motora	55
5.1	Osnovni podaci o motoru	55
5.2	Prikupljanje podataka iz simulacije	57
5.2.1	Histogrami svih podataka za koje se vršila simulacija	60
5.2.2	Histogrami ulaznih simulacijskih podataka, konvergirajući	61
5.2.3	Histogrami ulaznih simulacijskih podataka, divergirajući	62
5.3	Histogrami ulaznih podataka za treniranje mreže	63
5.4	Histogrami ulaznih podataka za validaciju mreže	64
5.5	Histogrami ulaznih podataka za konačni test mreže	64
5.6	Učenje mreže na podacima iz simulacije	65
5.7	Pregled rezultata i provjera pogreške	67
5.7.1	Usporedba vrijednosti simulacijskih podataka i podataka dobivenih neuronskom mrežom	67
5.7.1.1	Usporedba vrijednosti specifične potrošnje b_e iz simulacije i dobivene neuronskom mrežom	68
5.7.1.2	Usporedba vrijednosti zakretnog momenta na motoru M_M iz simulacije i dobivene neuronskom mrežom	69
5.7.1.3	Usporedba vrijednosti brzine vrtnje turbopuhala n_{TP} iz simulacije i dobivene neuronskom mrežom	70
5.7.1.4	Maseni protok na puhalu $m_{prot,P}$ iz simulacije i dobiven neuronskom mrežom	71
5.7.1.5	Maseni protok na turbini $m_{prot,T}$ iz simulacije i dobiven neuronskom mrežom	72

5.7.1.6	Tlak u usisnom kolektoru p_{UK} iz simulacije i dobiven neuronskom mrežom	73
5.7.1.7	Tlak u ispušnom kolektoru p_{IK} iz simulacije i dobiven neuronskom mrežom	74
5.7.1.8	Temperatura u ispušnom kolektoru T_{IK} iz simulacije i dobivena neuronskom mrežom	75
5.7.1.9	Temperatura u usisnom kolektoru T_{UK} iz simulacije i dobivena neuronskom mrežom	76
5.7.1.10	Maksimalni tlak procesa p_{max} iz simulacije i dobiven neuronskom mrežom	77
5.7.1.11	Temperatura na izlazu it turbine $T_{izl,T}$ iz simulacije i dobivena neuronskom mrežom	78
5.7.1.12	Maksimalna temperatura procesa T_{max} iz simulacije i dobivena neuronskom mrežom	79
5.7.2	Osvrt na analizu pogreške	79
5.8	Primjer vrijednosti neuronske mreže za puno opterećenje motora	80
5.9	Primjer vrijednosti neuronske mreže za 50% opterećenja motora	88
5.10	Osvrt na dobivene rezultate	92
6	Primjena razvijenog modela neuronske mreže za optimiranje uvjeta utilizacije i minimalizaciju specifične potrošnje goriva	93
6.1	Upravljanje početkom ubrizgavanja goriva i otvaranja ispušnog ventila s ciljem postizanja maksimalne toplinske snage ispušnih plinova	93
6.2	Zadovoljavanje potrebne toplinske snage uz zadržavanje konstantnog zakretnog momenta i brzine vrtnje motora	97
6.3	Optimiranje rada motora za minimalnu emisiju dušikovih oksida	101
7	Zaključak	103
	Popis literature	107
	Popis oznaka i simbola	113
	Popis slika	119
	Popis tablica	123
	Životopis	125

1 Uvod

1.1 Sporohodni brodski dizelski motori

U usporedbi s drugim strojevima za pogon broda dvotaktni sporohodni dizelski motori s prednabijanjem imaju prednosti zbog svog visokog stupnja djelovanja i pouzdanosti, 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 s 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 strojarne.

Motor je jedna od bitnih komponenti brodskog pogonskog postrojenja, koje mora tijekom eksploatacije 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 s 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 performanse 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 broskog 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 broskog 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 je razvoj i implementacija modela neuronskih mreža s 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.

U svrhu prikupljanja podataka koristili su se simulacijski modeli koji nisu koristili neuronske mreže. Podaci dobiveni i pohranjeni iz tih modela bili su osnova za treniranje, validaciju i test simulacijskih modela koji uključuju primjenu neuronskih mreža. Pošto svaka simulacija ne treba čitav skup parametara i zbog pojednostavljenja, nisu se koristili svi parametri koji su bili dostupni.

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 modeliranjem uspješno razviti simulacijski model brodskog dizelskog motora 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 prikupljanja podataka, i njihovoj obradi.

Podaci za razvoj neuronskih mreža preuzeti su iz raznih simulacijskih modela i raznih mjerenja. 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 s neuronskom mrežom.

Pokazalo se da neuronske mreže mogu dati precizna predviđanja parametara, ali s 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 s 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 otpadne topline kao i postizanje minimalne specifične potrošnje goriva.

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 samooptimizaciju 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 radu se ne koriste neuronske mreže. 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 brodskog pogonskog postrojenja tijekom stacionarnih idinamičkih uvjeta rada. Matematički model temelji se na energetske 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 razvijenog matematičkog modela korišten je i u ovoj disertaciji.

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 s 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 neizravne logike, ekspertni sustavi, umjetne neuronske mreže s 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 s 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. Umjetne neuronske mreže korištene su kao simulacijski alat, primale su ulaze koji su sadržavali radne parametre, a davale 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 s 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 s hardverom u petlji. U radu se koristi hibridni model. Prvo je razvijen model s kvazi-stacionarnim stanjima, a zatim je dodana 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 kao aktivacijske funkcije 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 s 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 (engl. *Exhaust Gas Recirculation*), VGT (engl. *Variable Geometry Turbo-charger*), 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 (engl. *Radial Basis Function*) neuronskih mreža spominje se u radu [15].


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

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

3 Matematički model dizelskog motora

Sustav dizelskog motora s 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 odvođe 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 s 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 ustrojava 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 $d\varphi$ u promatranom kontrolnom volumenu, određena je masom medija koja ulazi dm_u i izlazi dm_i iz kontrolnog volumena, masom dovedenoga goriva dm_g , dodatnog zraka dm_{dz} i masom medija koja zbog propuštanja izlazi izvan granica kontrolnog volumena dm_{pr} , a prikazana je jednadžbom:

$$\frac{dm}{d\varphi} = \frac{dm_u}{d\varphi} + \frac{dm_i}{d\varphi} + \frac{dm_g}{d\varphi} + \frac{dm_{dz}}{d\varphi} + \frac{dm_{pr}}{d\varphi} \quad (3.1)$$

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

$$dQ = dU + p dV \quad (3.2)$$

$$dU = d(mu) = u dm + m du \quad (3.3)$$

Uvrštavanjem jednadžbe (3.3) u (3.2) slijedi:

$$dQ = u dm + m du + p dV \quad (3.4)$$

Za medij u kontrolnom volumenu postavlja se sljedeća bilanca energije:

$$dQ = \sum_i dQ_i + \sum_j h_j dm_j \quad (3.5)$$

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:

$$\sum_i dQ_i = dQ_g + dQ_{st} \quad (3.6)$$

Iz izraza (3.4) i (3.5) slijedi:

$$m du + u dm = \sum_i dQ_i + \sum_j h_j dm_j - p dV \quad (3.7)$$

Jednadžba stanja idealnog plina glasi:

$$pV = mRT \quad (3.8)$$

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

$$u = f(T, p, \lambda) \quad (3.9)$$

$$R = f(T, p, \lambda) \quad (3.10)$$

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

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

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

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:

$$\frac{dT}{d\varphi} = \frac{\frac{1}{m} \left[-p \frac{dV}{d\varphi} + \sum_i \frac{dQ_i}{d\varphi} + \sum_j \left(h \frac{dm}{d\varphi} \right)_j - u \frac{dm}{d\varphi} - m \left(\frac{\partial u}{\partial \lambda} \right) \frac{d\lambda}{d\varphi} \right] - C}{\frac{\partial u}{\partial T} + \frac{A}{B} \frac{p}{T} \frac{\partial u}{\partial p}} \quad (3.13)$$

gdje su:

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

$$B = 1 - \frac{p}{R} \frac{\partial R}{\partial p} \quad (3.14)$$

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


Članovi A, B i C iz (3.14) sadrže utjecaj kompresibilnosti i disocijacije plinova izgaranja, tj. svojstva 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. Iz toga slijedi da je $u = u(T)$ i $\partial u / \partial p = 0$, i u tom slučaju se članovi A, B i C zanemaruju, a jednadžba za promjenu temperature u ovisnosti o kutu koljena koljenastog vratila glasi:

$$\frac{dT}{d\varphi} = \frac{1}{m \frac{\partial u}{\partial T}} \left[-p \frac{dV}{d\varphi} + \sum_i \frac{dQ_i}{d\varphi} + \sum_j h_j \frac{dm_j}{d\varphi} - u \frac{dm}{d\varphi} - m \left(\frac{du}{d\lambda} \right) \frac{d\lambda}{d\varphi} \right] \quad (3.15)$$

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:

$$\frac{dT_c}{d\varphi} = \frac{1}{m_c \frac{\partial u}{\partial T}} \left[-p \frac{dV}{d\varphi} + \sum_i \frac{dQ_i}{d\varphi} + \sum_j h_j \frac{dm_j}{d\varphi} - u \frac{dm}{d\varphi} - m \left(\frac{du}{d\lambda} \right) \frac{d\lambda}{d\varphi} \right] \quad (3.16)$$



Slika 3.2: Kontrolni volumen cilindra motora [2]

Djelovanjem tlaka u cilindru ostvaruje se rad definiran kao:

$$\frac{dW_c}{d\varphi} = p_c \frac{dV_c}{d\varphi} \quad (3.17)$$

Tlak u cilindru određen je jednadžbom stanja idealnog plina:

$$p_c = \frac{m_c T_c R_c}{V_c} \quad (3.18)$$

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

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

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:

$$V_c = \frac{d_c^2 \pi}{4} x + V_0 \quad (3.20)$$

gdje je V_0 kompresijski prostor. Ako primjenimo izraze za stapajni volumen $V_s = \frac{d_c^2 \pi}{2} r$ i za geometrijski stupanj kompresije $\varepsilon = \frac{V_s + V_0}{V_0}$, volumen cilindra je $V_c = \frac{V_s}{2r} x + \frac{V_s}{\varepsilon - 1} = \frac{V_s}{2} \left(\frac{x}{r} + \frac{2}{\varepsilon - 1} \right)$,

zajedno s jednadžbom (3.19) dobiva se izraz:

$$V_c = \frac{V_s}{2} \left[\frac{2}{\varepsilon - 1} + (1 - \cos\varphi) + \frac{1}{\lambda_m} \left(1 - \sqrt{1 - \lambda_m^2 \sin^2\varphi} \right) \right] \quad (3.21)$$

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

$$\frac{dV_c}{d\varphi} = \frac{V_s}{2} \left[\sin\varphi + \lambda_m \frac{\sin\varphi \cos\varphi}{\sqrt{1 - \lambda_m^2 \sin^2\varphi}} \right] \quad (3.22)$$

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 koeficijenta prijelaza topline, npr. u [60] dat je prikaz eksperimentalno određenih empirijskih jednadžbi za koeficijent konvektivnog prijelaza topline na stijenkama cilindra motora, usisnim i ispušnim kolektorima te kanalima u glavi motora. Jedna od češće primjenjivanih jednadžbi može se naći u [61] i glasi:

$$\alpha_c = 130,5 d_c^{-0,2} p_c^{0,8} T_c^{-0,53} \left[C_1 c_m + C_2 \frac{V_s T_{c,UZ}}{p_{c,UZ} V_{c,UZ}} (p_c - p_{cK}) \right] \quad (3.23)$$

gdje su:

p - tlak [bar],

$C_1 = 6,18 + 0,417 c_{vr}/c_m$ -tijekom izmjene radnog medija,

$C_1 = 2,28 + 0,308 c_{vr}/c_m$ -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]:

$$\alpha_c = C_1 V_c^{-0,06} p_c^{0,8} T_c^{-0,4} (c_m + C_2)^{0,8} \quad (3.24)$$

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:

$$A_c = A_{c,i} + 2d_c \pi \frac{h_k}{3} \quad (3.25)$$

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_{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:

$$\frac{dm_c}{d\varphi} = 0, \quad \frac{d\lambda_c}{d\varphi} = 0, \quad \frac{dQ_g}{d\varphi} = 0 \quad (3.26)$$

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

$$\frac{dT_c}{d\varphi} = \frac{1}{m_c \left(\frac{\partial u}{\partial T} \right)_c} \left[-\frac{p_c}{d\varphi} dV_c + \frac{dQ_{st,c}}{d\varphi} \right] \quad (3.27)$$

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

$$\frac{dm_c}{d\varphi} = \frac{dm_{dz}}{d\varphi} \quad (3.28)$$

$$\frac{dT_c}{d\varphi} = \frac{1}{m_c \left(\frac{\partial u}{\partial T} \right)_c} \left[-\frac{p_c}{d\varphi} dV_c + \sum_i \frac{dQ_{st,c}}{d\varphi} + h_{dz} \frac{dm_{dz}}{d\varphi} - u_c \frac{dm_{dz}}{d\varphi} - m_c \left(\frac{du}{d\lambda} \right)_c \frac{d\lambda_c}{d\varphi} \right] \quad (3.29)$$

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 cilindra 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. Oslobodena 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 i
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:


$$Q_g = f(\varphi) = x_g m_g H_d \eta_{izg} \quad (3.30)$$

$$x_g = \frac{Q_g}{m_g H_d \eta_{izg}} = 1 - \exp\left(-C \left(\frac{\varphi - \varphi_{PI}}{\varphi_{TI}}\right)^{m+1}\right) \quad (3.31)$$

$$\frac{dx_g}{d\varphi} = C (m+1) \left(\frac{\varphi - \varphi_{PI}}{\varphi_{TI}}\right)^m \exp\left(-C \left(\frac{\varphi - \varphi_{PI}}{\varphi_{TI}}\right)^{m+1}\right) \quad (3.32)$$

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.



Slika 3.3: Udio izgorjenog goriva i brzina izgaranja prema Vibeu

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 rasprskavača. Nakon što tlak na rasprskavaču prijeđe određenu, izvedbom i karakteristikama rasprskavača 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:

- O početku dobave visokotlačne pumpe goriva φ_{PD} ,
- O vremenu širenja tlačnog vala do početka ubrizgavanja $\Delta\varphi_{PU}$ i
- O zakašnjenju paljenja $\Delta\varphi_{ZP}$.

Njihova međuovisnost definira se kao:

$$\varphi_{PI} = \varphi_{PD} + \Delta\varphi_{PU} + \Delta\varphi_{ZP} \quad (3.33)$$

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

$$\Delta\varphi_{PU} = \frac{360 n_M L_{cig}}{a_g} \quad (3.34)$$

gdje je a_g brzina zvuka za gorivo u visokotlačnom cjevovodu.

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

$$\Delta\varphi_{PU,0} = \frac{360 n_{M,0} L_{cig}}{a_g} \quad (3.35)$$

$$\Delta\varphi_{PU} = \Delta\varphi_{PU,0} \frac{n_M}{n_{M,0}} \quad (3.36)$$

Zakašnjenje paljenja $\Delta\varphi_{ZP}$ definirano je jednadžbom (3.37) (Sitkei [65]) koja vrijedi za dizelsko gorivo s cetanskim brojem 52. Za dizelska goriva s drugom vrijednosti cetanskog broja potrebno je izvršiti ekstrapolaciju.

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

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

čade, 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:

$$\eta_{izg} = \frac{Q_{g,pr}}{m_{g,pr}H_d} \quad (3.38)$$

Teorijski stupanj djelovanja izgaranja je:

$$\eta_{izg} \approx \lambda \quad \text{za } \lambda \leq 1 \quad (3.39)$$

$$\eta_{izg} = 1 \quad \text{za } \lambda > 1 \quad (3.40)$$

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:

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

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

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

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

$$a = \frac{0,05 - d}{\lambda_{RB} \exp(c\lambda_{RB}) - \exp(c)} \quad (3.41)$$

$$b = a \exp(c) - 0,95 - d \quad (3.42)$$

$$c = -\frac{1}{\lambda_{RB}} \quad (3.43)$$

$$d = -0,0375 - \frac{\lambda_{RB} - 1,17}{15} \quad (3.44)$$

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:

$$\frac{dT_c}{d\varphi} = \frac{1}{m_c \left(\frac{\partial u}{\partial T}\right)_c} \left[-\frac{p_c}{d\varphi} dV_c + \frac{dQ_{st,c}}{d\varphi} + h_u \frac{dm_{c,u}}{d\varphi} + h_i \frac{dm_{c,i}}{d\varphi} - u_c \frac{dm_c}{d\varphi} - m_c \left(\frac{du}{d\lambda}\right)_c \frac{d\lambda_c}{d\varphi} \right] \quad (3.45)$$

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

$$\frac{dm_c}{d\varphi} = \frac{dm_{c,u}}{d\varphi} + \frac{dm_{c,i}}{d\varphi} \quad (3.46)$$

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:

$$\frac{dm}{d\varphi} = \alpha_v A_{v,geom} \psi p_1 \sqrt{\frac{2}{R_1 T_1}} \frac{dt}{d\varphi} \quad (3.47)$$

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

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

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

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

prestrujavanje se odvija brzinom zvuka, a funkcija protjecanja je:

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

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

$$A_{v,ef} = \alpha_v A_{v,geom} \quad (3.51)$$

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:

$$\frac{d\lambda_c}{d\varphi} = \frac{dm_c}{d\varphi} \quad (3.52)$$

$$\frac{d\lambda_c}{d\varphi} = \frac{\frac{dm_{c,i}}{d\varphi} \left(1 - \frac{m_c m_{g,c,i}}{m_{g,c} m_{c,i}}\right)}{L_{st} m_{g,c}} = \frac{\frac{dm_{c,i}}{d\varphi} \left(1 - \frac{\lambda_c L_{st} + 1}{\lambda_i L_{st} + 1}\right)}{L_{st} m_{g,c}} \quad \text{za} \quad \frac{dm_{c,i}}{d\varphi} > 0 \quad (3.53)$$

$$\frac{d\lambda_{c,i}}{d\varphi} = 0 \quad \text{za} \quad \frac{dm_{c,i}}{d\varphi} < 0 \quad (3.54)$$

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 jednažbom:

$$\frac{dm_{g,c}}{d\varphi} = \frac{dm_{c,i}}{d\varphi} \frac{1}{\lambda_i L_{st} + 1} \quad (3.55)$$

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 λ_A ,
2. potpunost ispiranja η_S ,
3. stupanj punjenja η_L i
4. stupanj čistoće β .

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):

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

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:

$$\eta_S = \frac{m_{c,sp}}{m_{c,uk}} = \frac{m_{c,sp}}{m_{c,zr} + m_{c,zpi}} = \frac{\text{trenutna masa svježeg punjenja u cilindru motora}}{\text{ukupna masa u cilindru motora}} \quad (3.57)$$

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):

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

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).

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

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 trenutak 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 potpunosti 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 brodске 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 njihov 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 cilindra, te u konačnici promjenu mase i pretička zraka koji se mogu desiti zbog te pojave:

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

$$\frac{dm_{\text{UK}}}{d\varphi} = \frac{dm_{\text{UK,P}}}{d\varphi} + \sum_i \frac{dm_{\text{UK},i}}{d\varphi} \quad (3.61)$$

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:

$$\frac{dQ_{\text{g,UK}}}{d\varphi} = 0, \quad \frac{dV_{\text{UK}}}{d\varphi} = 0 \quad (3.62)$$

$$\frac{dT_{\text{UK}}}{d\varphi} = \frac{1}{m_{\text{UK}} \left(\frac{\partial u}{\partial T}\right)_{\text{UK}}} \left[\frac{dQ_{\text{st,UK}}}{d\varphi} + \sum_i h_i \frac{dm_{\text{UK},i}}{d\varphi} - u_{\text{UK}} \frac{dm_{\text{UK}}}{d\varphi} - m_{\text{UK}} \left(\frac{du}{d\lambda}\right)_{\text{UK}} \frac{d\lambda_{\text{UK}}}{d\varphi} \right] \quad (3.63)$$

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:

$$\frac{dQ_{\text{st,UK}}}{d\varphi} = \alpha_{\text{UK}} A_{\text{UK}} (T_{\text{st,UK}} - T_{\text{UK}}) \frac{dt}{d\varphi} + \alpha_{\text{Ukan}} A_{\text{Ukan}} (T_{\text{st,Ukan}} - T_{\text{UK}}) \frac{dt}{d\varphi} \quad (3.64)$$

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

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

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

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

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

Reynoldsov se broj određuje pomoću izraza:

$$\text{Re} = \frac{4 \dot{m}_{\text{UK}}}{\pi d_{\text{UK}} \eta_{\text{UK}}} \quad (3.67)$$

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

$$\lambda_{\text{UK}} = 3,17 \cdot 10^{-4} T_{\text{UK}}^{0,772} \quad (3.68)$$

$$\eta_{\text{UK}} = 0,612 \cdot 10^{-6} T_{\text{UK}}^{0,609} \quad (3.69)$$

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

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

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:

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

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_{HZ} i koeficijent prolaza topline k_{HZ} , temperatura zraka nakon prolaska kroz hladnjak može se izračunati iz:

$$T''_{\text{zr}} = T'_{\text{zr}} - (T'_{\text{zr}} - T'_{\text{RV}}) \frac{1 - \exp\left[\left(\frac{W_{\text{zr}}}{W_{\text{RV}}} - 1\right) \frac{(A k)_{\text{HZ}}}{W_{\text{zr}}}\right]}{1 - \frac{W_{\text{zr}}}{W_{\text{RV}}} \exp\left[\left(\frac{W_{\text{zr}}}{W_{\text{RV}}} - 1\right) \frac{(A k)_{\text{HZ}}}{W_{\text{zr}}}\right]} \quad (3.72)$$

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_{zr} i W_{RV} , a predstavljaju produkt masenog protoka \dot{m} i specifičnog toplinskog kapaciteta c medija koji se promatra.



Slika 3.7: Bezdimenzijska promjena temperature zraka za unakrsni izmjenjivač topline

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


$$\frac{dQ_{\text{HZ}}}{d\varphi} = W_{\text{zr}} (T'_{\text{zr}} - T''_{\text{zr}}) \frac{1}{6n_{\text{M}}} \quad (3.73)$$

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

$$p_{zr}'' = p_{zr}' - \Delta p_0 \left(\frac{\dot{m}_P}{\dot{m}_{P,0}} \right)^2 \quad (3.74)$$

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:

$$\frac{dT_{IK}}{d\varphi} = \frac{1}{m_{IK} \left(\frac{\partial u}{\partial T} \right)_{IK}} \left[\frac{dQ_{st,IK}}{d\varphi} + \sum_i h_i \frac{dm_{IK,i}}{d\varphi} - u_{IK} \frac{dm_{IK}}{d\varphi} - m_{IK} \left(\frac{du}{d\lambda} \right)_{IK} \frac{d\lambda_{IK}}{d\varphi} \right] \quad (3.75)$$

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 $dm_{IK,i}/d\varphi > 0$:

$$\frac{d\lambda_{IK}}{d\varphi} = \frac{\sum_i \frac{dm_{IK,i}}{d\varphi} \left(1 - \frac{\lambda_{IK} L_{st} + 1}{\lambda_i L_{st} + 1} \right)}{L_{st} m_{g,IK}} \quad (3.76)$$

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

$$\frac{dm_{IK}}{d\varphi} = \frac{dm_{IK,T}}{d\varphi} + \sum_i \frac{dm_{IK,i}}{d\varphi} \quad (3.77)$$

3.4.1 Prijelaz topline u ispušnom kolektoru

Ispušni plinovi koji izlaze iz cilindra motora i ulaze u ispušni kolektor imaju visoku temperaturu, pa je prijelaz topline s radnog medija na stijenske 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:

$$\frac{dQ_{st,IK}}{d\varphi} = \alpha_{IK} A_{IK} (T_{st,IK} - T_{IK}) \frac{dt}{d\varphi} + \alpha_{Ikan} A_{Ikan} (T_{st,Ikan} - T_{IK}) \frac{dt}{d\varphi} \quad (3.78)$$

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:

$$\lambda_{IK} = 2,02 \cdot 10^{-4} T_{IK}^{0,837} \quad (3.79)$$

$$\eta_{IK} = 0,355 \cdot 10^{-6} T_{IK}^{0,679} \quad (3.80)$$


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

$$\alpha_{Ikan} = 3,27 \left(1 - 0,797 \frac{h_{IV}}{d_{IV}} \right) d_{sr,Ikan}^{-1,5} T_{IK}^{0,517} \left(\frac{dm_{Ikan}}{dt} \right)^{0,5} \quad (3.81)$$

3.5 Turbopuhalo

Numerički model turbopuhala sastoji se od 2 dijela – od modela turbine na ispušne plinove i modela puhalo. Uravnoteženjem momenta dobivenog od turbine i momenta potrebnog za rad puhalo, 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 puhalo 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:

$$\frac{dm_T}{d\varphi} = \alpha_T A_{T,\text{geom}} \psi p_{\text{IK}} \sqrt{\frac{2}{R_{\text{IK}} T_{\text{IK}}}} \frac{dt}{d\varphi} \quad (3.82)$$

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

Adijabatski stupanj djelovanja turbine η_T jest omjer stvarnog i adijabatskog pada entalpije u turbini:

$$\eta_T = \frac{\Delta h_T}{\Delta h_{s,T}} \quad (3.83)$$

gdje je Δh_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:

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

s tim da je π_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_T i brzine strujanja c_0 , koja odgovara adijabatskom padu entalpije, je bezdimenzijska značajka brzine ν :

$$\nu = \frac{u_T}{c_0} = \frac{u_T}{\sqrt{2 \Delta h_{s,T}}} \quad (3.85)$$


Eksperimentalnim mjerenjima na različitim turbinama utvrđeno je da su koeficijent protoka α_T i maksimalni adijabatski stupanj djelovanja $\eta_{T,\text{max}}$ funkcije omjera tlakova π_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 $\eta_T/\eta_{T,\text{max}}$ ovisi o izvedbi lopatica i neznatno se mijenja za različite omjere tlakova π_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 α_T prikazuje se kao izlomljena i linearna funkcija bezdimenzijske značajke vrtnje za određenu vrijednost omjera tlakova π_T .


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 $T_0 = 288 \text{ K}$ i za koje vrijedi:


$$\pi_P = f \left(\frac{dV_{288}}{dt}, n_{\text{TP},288} \right) \quad (3.86)$$



Slika 3.10: Polje karakteristika radialne turbine na ispušne plinove



Slika 3.11: Polje karakteristika aksijalne turbine na ispušne plinove



Slika 3.12: Polje karakteristika puhalo

$$\eta_P = f\left(\frac{dV_{288}}{dt}, n_{TP,288}\right) = \frac{\Delta h_{s,P}}{\Delta h_P} \quad (3.87)$$

Maseni protok kroz puhalo određen je jednadžbom:

$$\frac{dm_P}{d\varphi} = \frac{dV_{288}}{dt} \sqrt{\frac{T_0}{T_{atm}}} \frac{p_{atm}}{R_{atm} T_{atm}} \frac{dt}{d\varphi} \quad (3.88)$$

a korigirani volumni protok i broj okretaja dobivaju se iz:

$$\frac{dV_{288}}{dt} = \sqrt{\frac{T_0}{T_{atm}}} \frac{dV_{zr}}{dt} \quad (3.89)$$

$$n_{TP,288} = n_{TP} \sqrt{\frac{T_0}{T_{atm}}} \quad (3.90)$$

Rad potreban za pogon puhalo tijekom jednog koraka proračuna je:

$$W_P = \int \frac{dm_P}{d\varphi} \frac{\Delta h_{s,P}}{\eta_{s,P} \eta_{meh} \eta_{vol}} d\varphi \quad (3.91)$$

Opis polja karakteristika puhalo ima značajan utjecaj na simulaciju procesa u motoru, pa je tom problemu posvećena posebna pozornost. Polje karakteristika puhalo prikazuje se funkcijama $\pi_P = f(\dot{V}, n)$ i $\eta_P = f(\dot{V}, n)$, te je takav pristup preuzet iz [77]. Funkcije $\pi_P = f(\dot{V})$ i $\eta_P = f(\dot{V})$ mogu se opisati regresijskim polinomima 4. ili 5. reda za konstantnu brzinu vrtnje. Brzina vrtnje turbopuhala i stupanj djelovanja puhalo 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:

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

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 puhalo prikazan je regresijskim polinomom:

$$\eta_P = \sum_{i=0}^2 A_i \pi_P^i + \dot{V}^2 \sum_{i=0}^2 B_i \pi_P^i + (\pi_P - 1)^{2K} \sum_{i=0}^2 C_i \pi_P^i + (\pi_P - 1)^K \sum_{i=0}^2 D_i \pi_P^i \quad (3.93)$$

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 puhalo i rotora turbine na ispušne plinove, koji su međusobno povezani vratilom. Zajedničko vratilo osigurava krutu vezu između puhalo 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 puhalo ubrzava ili usporava rotor turbopuhala. Osim o veličini razlike zakretnih momenata, prirast brzine vrtnje rotora ovisi i o momentu tromosti rotora turbopuhala:

$$\frac{dn_{TP}}{dt} = \frac{M_T - M_P}{J_{TP}} \frac{1}{2\pi} \frac{dt}{d\varphi} = \frac{M_T - M_P}{J_{TP}} \frac{1}{120 n_M \pi} \quad (3.94)$$

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

$$M_T = \frac{dW_T}{dt} \frac{1}{2\pi n_{TP}} = \frac{dm_T}{d\varphi} \Delta h_{s,T} \eta_T \frac{1}{2\pi n_{TP}} \frac{d\varphi}{dt} \quad (3.95)$$

$$M_P = \frac{dW_P}{dt} \frac{1}{2\pi n_{TP}} = \frac{dm_P}{d\varphi} \frac{\Delta h_{s,P}}{\eta_P \eta_{meh} \eta_{vol}} \frac{1}{2\pi n_{TP}} \frac{d\varphi}{dt} \quad (3.96)$$

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:

$$(J_M + J_{Pot}) \frac{d\omega_M}{dt} = M_M + M_{Pot} \quad (3.97)$$

gdje su J_M i J_{Pot} momenti tromosti motora i potrošača.

Promjena brzine vrtnje dizelskog motora može se prikazati jednadžbom:

$$\frac{dn_M}{dt} = \frac{M_M + M_{Pot}}{J_M + J_{Pot}} \frac{1}{2\pi} \frac{dt}{d\varphi} \quad (3.98)$$

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

$$\frac{dn_M}{d\varphi} = \frac{P_M + P_{Pot}}{J_M + J_{Pot}} \left(\frac{1}{2\pi} \right)^2 \frac{1}{n_M} \frac{dt}{d\varphi} = \frac{P_M + P_{Pot}}{360 n_M^2 (J_M + J_{Pot})} \left(\frac{1}{2\pi} \right)^2 \quad (3.99)$$

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

$$P_{ind} = \frac{2 n_M z}{\tau} \int \frac{dW_c}{d\varphi} d\varphi \quad (3.100)$$

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

$$P_{ind} = \frac{2 n_M z}{\tau} V_s p_{sr,ind} \quad (3.101)$$

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_M koju motor predaje na izlaznoj spojci potrošaču, manja od indicirane snage P_{ind} upravo za vrijednost

navedenih gubitaka. Efektivna snaga motora može se izraziti preko srednjega efektivnog tlaka $p_{sr,ef}$, koji se dobije na način da se od indiciranog tlaka p_{ind} oduzme srednji tlak gubitaka trenja i pogona pomoćne opreme $p_{sr,tr}$:

$$P_M = \frac{2n_M z}{\tau} V_s p_{sr,ef} = P_{ind} \frac{p_{sr,ef}}{p_{sr,ind}} \quad (3.102)$$

$$p_{sr,ef} = p_{sr,ind} - p_{sr,tr} \quad (3.103)$$

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

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

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

gdje je d_c promjer cilindra u mm.

Utjecaj opterećenja motora s izravnim ubrizgavanjem definira se kao:

$$\Delta p_{tr,2} = 0,0002 p_{sr,ef}^3 - 0,006 p_{sr,ef} \quad \text{bar} \quad (3.105)$$

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

$$\Delta p_{tr,3} = \left(\frac{p_{UK}}{p_{atm}} - 1 \right) \sqrt{0,1874 - 0,018 c_m} \quad \text{bar} \quad (3.106)$$

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

$$\Delta p_{tr,4} = -0,005 (T_{ulja} - T_{ulja,0}) \quad \text{bar} \quad (3.107)$$

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

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

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

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. Regulator s proporcionalnim djelovanjem (P),
2. Regulator s integracijskim djelovanjem (I),
3. Regulator s derivacijskim djelovanjem (D),
4. Regulator 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_p određuje se nova vrijednost postavnog člana y , što će utjecati na ispravljanje regulirane veličine prema željenoj vrijednosti. Jednadžba P-regulatora glasi:

$$y(t) = K_p e(t) \quad (3.110)$$

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:

$$y(t) = K_p \left(e(t) + \frac{1}{T_i} \int_{t_0}^{t_1} e(t) dt \right) \quad (3.111)$$

gdje je T_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, PI-regulator 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)

$$y(t) = K_p \left(e(t) + \frac{1}{T_i} \int_{t_0}^{t_1} e(t) dt + T_d \frac{de(t)}{dt} \right) \quad (3.112)$$

ili

$$y(t) = K e(t) + K_i \int_{t_0}^{t_1} e(t) dt + K_d \frac{de(t)}{dt} \quad (3.113)$$

gdje je T_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 parametara regulatora može postići željeno ponašanje reguliranog sustava.

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

$$\frac{m_R}{c_R} \frac{d^2 x_R}{dt^2} + \frac{d_R}{c_R} \frac{dx_R}{dt} + \frac{F_{tr}}{c_R} \text{sign} \left(\frac{dx_R}{dt} \right) + x_R = K_p \left(n_R + \frac{1}{T_I} \int n_R dt + T_D \frac{d}{dt} n_R \right) \quad (3.114)$$

gdje su:

m_R - slobodne mase regulatora,

d_R - prigušenje regulatora,

c_R - krutost opruge regulatora,

F_{tr} - Coulombovo trenje,

x_R - hod letve goriva i

n_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


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.



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



Slika 3.14: Djelovanje visokotlačne pumpe goriva s VIT funkcijom [78]



Slika 3.15: Ubrizgana masa goriva po procesu prikazana kao karakteristika visokotlačne pumpe goriva: a) ovisno o kutnoj brzini i b) ovisno o hodu letve goriva [2]

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.


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 signala 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.

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



Slika 3.16: Dijagram toka signala za model brodskog dizelskog motora s prednabijanjem [2]

ventila i početak kompresije u prvome cilindru. Proračun stanja u ostalim cilindrima pomaknut je za odgovarajući fazni kut, unaprijed definiran redosljedom paljenja. Koršten 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 simulacija i 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 bržim 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 dizelskim motorom primjenjuje se metoda simuliranja dinamičkih procesa, koji se odnose na promatrani sustav i uvjete kojima je izložen. Ovakva metoda 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.



Slika 3.17: Proces izrade simulacijskog modela

Za izradu računalno-simulacijskog modela korištena je računalna aplikacija razvijena unutar okruženja MATLAB i 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

sustava sa sporohodnim dizelskim motorom kao pogonskim strojem, elementi modela su sastavljeni od 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 cilindra, turbina, puhalo, dinamika turbopuhala i dinamika motornog mehanizma.

U cilindar motora, za vrijeme procesa ubrizgavanja goriva, dobavlja se gorivo pomoću visokotlačne pumpe. Regulator određuje potrebnu količinu goriva za ubrizgavanje, 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 cilindra. 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 cilindra za vrijeme ispuha i ispiranja, tijekom izgaranja i rad. Rad u cilindru motora računa se integriranjem jednadžbe $p dV$ za cijeli radni proces 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 cilindra, a potrebne za element ispušnog kolektora. Mase koje ulaze u cilindre utječu na promjene stanja u kolektoru zraka za ispiranje cilindra. 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 cilindra, utječe i maseni protok na puhalu, a za računanje temperature nakon hladnjaka zraka potreban je i omjer tlakova odnosno tlak nakon puhalo. 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 puhalo, 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 simuliran sa svim elementima stvarnog PID elektroničkog regulatora, te ispitan i potpuno usklađen s realnim.

Simulacijski model omogućuje simuliranje rada brodskih propulzijskih sustava s dvo-taktnim sporohodnim motorom i vijčanim propulzorom. Jednostavna je prilagodba modela različitim izvedbama propulzijskih sustava. Simuliranjem modela na računalu s procesorom koji radi s taktom bržim 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. Razlika u brzini izvođenju između modela opisanog u [77] i onog izrađenog u simulinku [81] proizlazi iz razlike u brzini izvođenja u fortranu i MATLAB-u. Modeli su u konceptu i idejno identični, ali model napisan u SIMULINK-u specijaliziran je za rad brodskoga sporohodnog dizelskog motora u svrhu propulzije broda, dok je model napisan u fortranu korišten u svrhu simuliranja dizelskog motora za pogon generatora. Za svrhe detaljnih istraživanja, za vrijeme prijelaznih procesa ili dijelova samoga ciklusa u motoru, bira se korak računanja od $0,1^\circ$ 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 dovesti 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 (engl. *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 (engl. *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 s povratnim širenjem (engl. *the Back-Propagation learning algorithm*) za višeslojne perceptrone ponovno je otkriven i od tog trenutka kreće razvoj cijelog znanstvenog polja neuronskih mreža.

- 1990-tih. Razvija se pod-područje mreža temeljenih na "radial basis funkcijama", (engl. *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 odnosno računalni sustav koji oponaša način na koji ljudski mozak obrađuje i pohranjuje podatke. 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. Neuronska mreža ima zapisanu informaciju u težinskim vrijednostima između različitih neurona koji su najmanje matematičke jedinice za procesiranje podataka.

Umjetne neuronske mreže koje najvjernije oponašaju biološke koriste se u medicini za proučavanje rada mozga kao i istraživanje bolesti mozga. Neke od spoznaja u medicini integriraju se u nove algoritme za učenje umjetnih neuronskih mreža.

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 tijekom cijelog vremena korištenja. Koristi se u onim sustavima koji moraju učiti dok se koriste.

Neuronske mreže mogu učiti na dva načina, nadzirano i nenadzirano. 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 težinske vrijednosti.

Algoritmi za učenje mreža najčešće uključuju traženje optimalnih težinskih vrijednosti. Postoje algoritmi (npr. NEAT, engl. *NeuroEvolution of Augmenting Topologies*) koji uz promjenu težinskih vrijednosti 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 kojima 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 vrijednosti i relacijama među vezama. 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 koristiti 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 uređaj koji ima limitirane resurse za pohranu podataka i procesiranje.

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

Kao alat za učenje neuronskih mreža odabran je paket (biblioteka) FANN (engl. *Fast Artificial Neural Network Library*), koja je javno dostupnog koda pisanog u programskom jeziku C. U biblioteci je implementirana višeslojna mreža s 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. Neuron čini osnovnu jedinicu za procesiranje ulaznog signala u izlazni. 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.

$$u_k = \sum_{j=0}^p w_{kj}x_j \quad (4.1)$$

Riječ *umjetno* se naglašava, jer iako umjetni neuron oponaša biološki, značajno se razlikuje od biološkog i predstavlja samo njegov pojednostavljeni model.


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), aktivacijsku funkciju f te aktivacijski prag θ_k .

Oznake na slikama 4.1 i 4.2 su sljedeće:

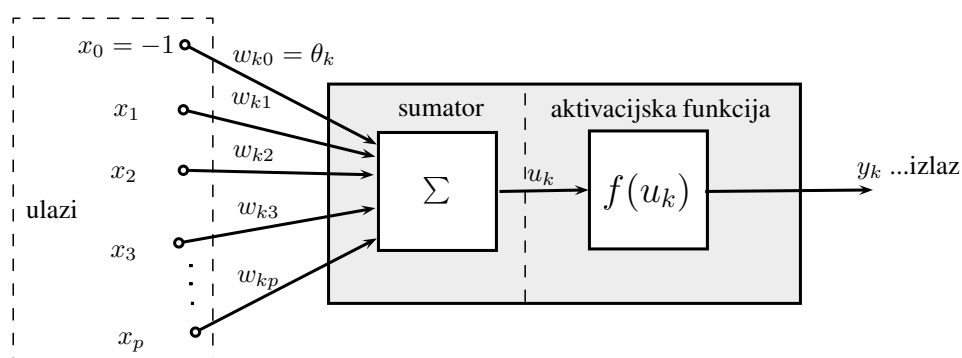
- k – indeks neurona,
- p – ukupni broj ulaza u neuron,
- x – ulaz u neuron (jedan ili više),
- w – težinski koeficijenti (daju težinu svakoj vezi) i
- y – izlaz iz neurona (samo jedan).

Umjesto praga za pojedini neuron, često se koristi dodatni ulaz koji ima vrijednost 1 ili -1 (slika 4.2). Ta vrijednost pomnožena s pripadajućom težinom veze u sumatoru neurona, daje ekvivalent vrijednosti praga. Taj dodatni ulaz najčešće se označava s indeksom 0 i zajednički je za čitav sloj.

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



Slika 4.1: Prikaz neurona s pragom



Slika 4.2: Prikaz neurona s dodatnom težinom umjesto praga

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 rješava. 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 monotonno rastuće ili padajuće, definirane u području u kojem se koriste. Algoritmi za učenje neuronskim mrežama obično zahtijevaju poznavanje derivacije aktivacijske funkcije, pa je potrebno da iste imaju i definiranu neprekidnu derivaciju (npr. \sin , \cos , \log), premda nije uvijek (npr. funkcija praga).

4.3.1 Logistička sigmoidna funkcija

Logistička sigmoidna funkcija (slika 4.3(a)), 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 (4.2):



(a) Logistička sigmoidna funkcija



(b) Simetrična logistička sigmoidna funkcija

Slika 4.3: Logističke sigmoidne funkcije


$$y(x) = \frac{1}{1 + e^{-x}} \quad (4.2)$$

Simetrični oblik logističke sigmoidne funkcije (slika 4.3(b)) jest (4.3):


$$y(x) = \frac{2}{1 + e^{-x}} - 1 \quad (4.3)$$

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

Stepenaste sigmoidne funkcije su aproksimacije logističke sigmoidne funkcije s 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.



(a) Stepenasta sigmoidna funkcija




(b) Simetrična stepenasta sigmoidna funkcija

Slika 4.4: Stepenaste sigmoidne funkcije

Stepenasta sigmoidna funkcija aproksimacija je sigmoidne funkcije. Može je zamijeniti u fazi eksploatacije mreže jer ima manje zahtjeve za računanjem zbog toga što je funkcija aproksimacija sigmoidne preko linearnih segmenata.

4.3.2 Funkcija hiperboličkog tangensa

Funkcija hiperboličkog tangensa (4.4) 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.



Slika 4.5: Funkcija hiperboličkog tangensa


$$y(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (4.4)$$

ili jednostavnije kao

$$y(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (4.5)$$

4.3.3 Linearna funkcija

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




Slika 4.6: Linearna funkcija

$$y(x) = x \quad (4.6)$$

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 4.7: Funkcija praga

Izraz za funkciju praga je:


$$y(x) = \begin{cases} 0 & , \text{ za } x < 0; \\ 1 & , \text{ za } x \geq 0. \end{cases} \quad (4.7)$$

dok je za simetričan oblik:

$$y(x) = \begin{cases} -1 & , \text{ za } x < 0; \\ 1 & , \text{ za } x \geq 0. \end{cases} \quad (4.8)$$

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 nesimetrični oblik donja granica je 0, a za simetričan -1.



Slika 4.8: Limitirane linearne funkcije

Izraz za limitiranu linearnu funkciju je:

$$y(x) = \begin{cases} 0 & , \text{ za } x < -1; \\ x & , \text{ za } x \geq -1 \text{ i } x < 1; \\ 1 & , \text{ za } x \geq 1. \end{cases} \quad (4.9)$$

dok je za simetričan oblik limitirane linearne funkcije:

$$y(x) = \begin{cases} -1 & , \text{ za } x < 0; \\ x & , \text{ za } x \geq 0 \text{ i } x < 1; \\ 1 & , \text{ za } x \geq 1. \end{cases} \quad (4.10)$$

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.

Izraz za Elliot funkciju je:


$$y(x) = \frac{0,5x}{1+|x|} + 0,5 \quad (4.11)$$

dok je izraz za simetričan oblik Elliot funkcije:

$$y(x) = \frac{x}{1+|x|} \quad (4.12)$$



(a) Elliot funkcija



(b) Simetrična Elliot funkcija

Slika 4.9: Elliot funkcije

4.3.7 Gaussova funkcija


Gaussova funkcija može se koristiti kod MLP mreža, ali obično se koristi kod RBFN (engl. *Radial Basis Function Networks*).

Običan oblik:

$$y(x) = e^{-x^2} \quad (4.13)$$

Simetričan oblik:


$$y(x) = 2e^{-x^2} - 1 \quad (4.14)$$



Slika 4.10: Gaussove funkcije

4.4 Modeliranje s 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 prethodnog sloja prema neuronima sljedećeg sloja, tako da su neuroni iz jednog sloja u vezi samo s neuronima iz prethodnog i iz sljedećeg sloja. Neuroni unutar jednog sloja nisu međusobno direktno povezani. MLP dobro uče i na podacima koji u sebi mogu sadržavati pogrešku ili šum, premda nemaju točnost kao RBFN (engl. *Radial Basis Function Networks*) i GRNN (engl. *General Regression Neural Networks*), koje zahtjevaju podatke s vrlo malom pogreškom.



Slika 4.11: 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 ugniježdene ponavljajuće petlje za razvoj neuronskih mreža koji se sastoji iz pet sljedećih koraka (slika 4.12):

Korak 1.: Odrediti skup zahtjeva, ciljeva i ograničenja koje mora zadovoljiti neuronska mreža i to dokumentirati kao specifikaciju pod nazivom Specifikacija izvedbe neuronske mreže (engl. *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 (engl. *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 (engl. *Variations of Artificial Neural Network Topologies*), u kojoj se mijenjaju parametri same arhitekture mreže. Srednja petlja, Variacija paradigmi umjetne neuronske mreže (engl. *Variations of ANN Paradigms*), uključuje promjenu tipa neuronske mreže koja se koristi. Vanjska petlja, Selekcija i kombinacija ulaznih neurona (engl. *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 (engl. *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 s kodom za izvršavanje. Implementacija se dokumentira u Integracijskom dokumentu (engl. *Network Integration Document*).

Korak 5.: Nezavisna testiranja i verifikacije ispitivanja proizlaze iz Plana testiranja podataka (engl. *Network Test Plan*) i iz dokumenta Analize podataka. Kao rezultat ovog koraka je Izvještaj o testiranju mreže (engl. *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 potrebno 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 4.12: Rodvoldov model razvoja neuronske mreže [82]

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 polja 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 s 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 s različitim izlaznim varijablama.

4.5.1.3 Priprema skupa podataka za treniranje, validaciju i testiranje

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

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

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

Ako postoji manji skup dostupnih podataka mogu se koristiti testovi krosvalidacije (engl. *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 ekstrapolacije mreže, potrebno je imati na umu da neuronske mreže kod ekstrapolacije podataka imaju značajno veću pogrešku. Djelomično se prethodno može korigirati s povećanjem broja točaka za treniranje koje se nalaze na rubu domene ulaznih vrijednosti.

Broj potrebnih podataka u vezi je sa željenom točnošću 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, skaliranje 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, potrebno je ulazne vrijednosti isto tako 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 rijede 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 težinskih vrijednosti

Izbor aktivacijske funkcije umnogu 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 inicijalnih težinskih vrijednosti. 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 s 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 (slika 4.13a) nije poželjna zbog dugog vremena trajanja, a prevelika brzina učenja može uzrokovati divergenciju, tj. onemogućiti učenje (slika 4.13b).



Slika 4.13: Utjecaj brzine učenja na konvergenciju

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

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

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

Funkcija za ocjenu pogreške može se pisati kao:

$$E_{\text{SSE}}(w_{ij}) = \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^C (targ_{i,j} - out_{i,j})^2 \quad (4.15)$$

Izraz (4.15) poznat je kao suma kvadrata pogreške. Radi se o totalnoj kvadratnoj pogrešci sumiranoj preko svih izlaznih jedinica j i svih uzoraka za treniranje i . N je broj uzoraka za treniranje, a C broj izlaznih jedinica (broj izlaznih varijabli iz neuronske mreže). Sumiraju se kvadrati dobivenih razlika između tražene vrijednosti i one dobivene na izlazu iz neurona u izlaznom sloju. 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 pogreške 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

$targ_j$:

$$\Delta w_{ij} = \eta(targ_j - out_j)in_i \quad (4.16)$$

Pravilo učenja perceptrona proizlazi iz pravila Delta:

$$\Delta w_{kl} = \eta \sum_p (targ_l - out_l) \cdot f' \left(\sum_n in_n w_{nl} \right) in_k \quad (4.17)$$

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 koristiti skup podataka za validaciju. Uvjeti za prekid učenja neuronske mreže mogu biti ili postotak uspješne klasifikacije ili odstupanja između željenih i dobivenih izlaznih vrijednosti.

Ako je dobivena manja srednja 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 (skup podataka za učenje, skup podataka za validaciju i skup podataka 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 odabir 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 skupa podataka 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. 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 skupa 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 s manjim brojem neurona pa im povećavati broj, ili uzeti veći broj neurona pa ga smanjivati.

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

Kod prevelikog početnog broja skrivenih neurona ANN može imati problema s 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 s 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 s 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 ovom 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

Klasični sporohodni brodski dizelski motor 6S50MC MAN&BW, čiji su podaci upotrebjeni za numeričke simulacije, 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 upravljani elektrohidraulički pogon ispušnih ventila i ubrizgavanja goriva).

Opis podatka	Vrijednost
Vrsta procesa	2 takti, 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 turbopuhalom velike efikasnosti)	171 g/kWh, 100% opterećenja
Stupanj kompresije (dobiven proračunom)	17,2
Omjer polužja	0,436
Volumen ispušnog kolektora	6,13 m ³
Volumen kolektora ispirnog zraka (ukupni s rashladnikom zraka)	7,179 m ³


Tablica 5.1: Osnovni podaci analiziranog motora 6S50MC MAN&BW [81]

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 NO_x, SO_x i čađe, važna je prije svega 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 [81]

Slika 5.2 prikazuje usporedbu rezultata numeričkih simulacija s izmjerenim vrijednostima pri ispitivanju motora u tvornici proizvođača. Iz slike se vidi dobro poklapanje izračunatih vrijednosti i rezultata mjerenja 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 prikupljaju u bazu iz koje se kasnije prema potrebi koriste oni koji su potrebni za simulaciju.

Obzirom da se pri izradi ovoga rada nije raspolagalo s dostatnim brojem 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 "intelligentnima" omogućuju vrlo veliko područje mogućnosti prilagodbe motora u raznim 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 u ovom radu korišteni rezultati numeričkih simulacija.

Kako se u ovom slučaju radi o brodskom dvotaktnom dizelskom motoru s prednabija-

njem, 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 položaj letve goriva. Vidjeti će se da se pouzdan rad motora može postići tek iznad određenog položaja letve goriva.

Obzirom da se za motor unaprijed 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 letve goriva. Obzirom na količinu ubrizganog goriva, koja je određena položajem letve 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 postavljene uvjete to uopće nije u stanju postići. Ovako dobiveni rezultati, temeljeni na položaju letve 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 postavljene 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 s 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 skup podataka za treniranje, validaciju i test. Prilikom prikupljanja i odabira potrebnih podataka, potrebno je zadati i ograničenja, 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 izvišavanja. Podaci koji su poslužili za treniranje i validaciju mreže generirani su iz simulacijskog modela [81].

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 proizvoljno distribuirani 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 obzirom na referentna postavke motora. Isto vrijedi i za pomicanje kuta otvaranja ispušnih ventila *EVO*.

Upravljanje ulaznim vrijednostima 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


Ulazni parametar	Raspon vrijednosti	Jedinica
n_M	od 75 do 130	min^{-1}
x_{reg}	od 12 do 82.7	mm
<i>SOI</i>	od -10 do +10	$^{\circ}\text{KV}$
<i>EVO</i>	od -20 do +20	$^{\circ}\text{KV}$

Tablica 5.2: Raspon vrijednosti ulaznih parametara

Redni broj.	Oznaka varijable	Opis varijable	Dimenzija
Oznaka konvergencije			
1	<i>Konverg</i>	Konvegencija proračuna	1-Da, 0-Ne
Ulazne vrijednosti			
2	n_M	Brzina vrtnje motora	min^{-1}
3	x_{reg}	Pomak letve goriva	mm
4	<i>SOI</i>	Pomak ubrizgavanja	$^{\circ}\text{KV}$
5	<i>EVO</i>	Pomak otvaranja ispušnih ventila	$^{\circ}\text{KV}$
Izlazne vrijednosti			
6	M_M	Zakretni moment na motoru	Nm
7	P_{ef}	Snaga motora	kW
8	b_e	Specifična potrošnja goriva	g/kWh
9	T_{IK}	Temperatura u ispušnom kolektoru	K
10	$T_{\text{izl,T}}$	Temperatura na izlazu iz turbine	K
11	T_{UK}	Temperatura u usisnom kolektoru	K
12	$m_{\text{prot,T}}$	Maseni protok na turbini	kg/s
13	λ_{IK}	Pretičak zraka u ispušnom kolektoru	-
14	p_{UK}	Tlak u usisnom kolektoru	Pa
15	p_{IK}	Tlak u ispušnom kolektoru	Pa
16	n_{TP}	Brzina vrtnje turbopuhala	min^{-1}
17	$m_{\text{prot,P}}$	Maseni protok na puhalu	kg/s
18	p_{max}	Maksimalni tlak u cilindru	Pa
19	T_{max}	Maksimalna temperatura u cilindru	K
20	Q_{st}	Toplina predana stijenkama cilindra	K

Tablica 5.3: Popis ulaznih i izlaznih varijabli korištenih za istraživanje

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 s kojim se podacima ulazi u simulaciju, za koje je podatke simulacija konvergirala, a za koje nije. Za kvalitetno pokrivanje kompletne domena ulaznih vrijednost bitna je pravilna distribucija ulaznih podataka.

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. Bilježi se svaki neočekivani prekid program.


Razdioba podataka po slučajnom odabiru omogućuje kvalitetniju informaciju u odnosu na strukturiranu razdiobu ulaznih podataka.

Distribucije ulaznih podataka prikazane su preko histograma. 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 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 vrijednosti pojedine ulazne varijable bili podjednako zastupljene.

5.2.2 Histogrami ulaznih simulacijskih podataka, konvergirajući



Slika 5.4: Histogrami ulaznih simulacijskih podataka, konvergirajući

Kao kriterij konvergencije za svaku pojedinu simulaciju zadana je vrijednost specifične potrošnje goriva koja se ne bi trebala mijenjati iz procesa u proces ako je postignuto stacionarno stanje. Zato uvjet konvergencije glasi da se vrijednost specifične potrošnje iz procesa u procesa razlikuje manje od 0.01 g/kWh. Ako je to postignuto u najviše 48 procesa simulacija je konvergirala. Ako nije, simulacija je divergirala. Isto tako ako simulacija nije konvergirala i nije se postiglo 48 procesa tad je "pukla".

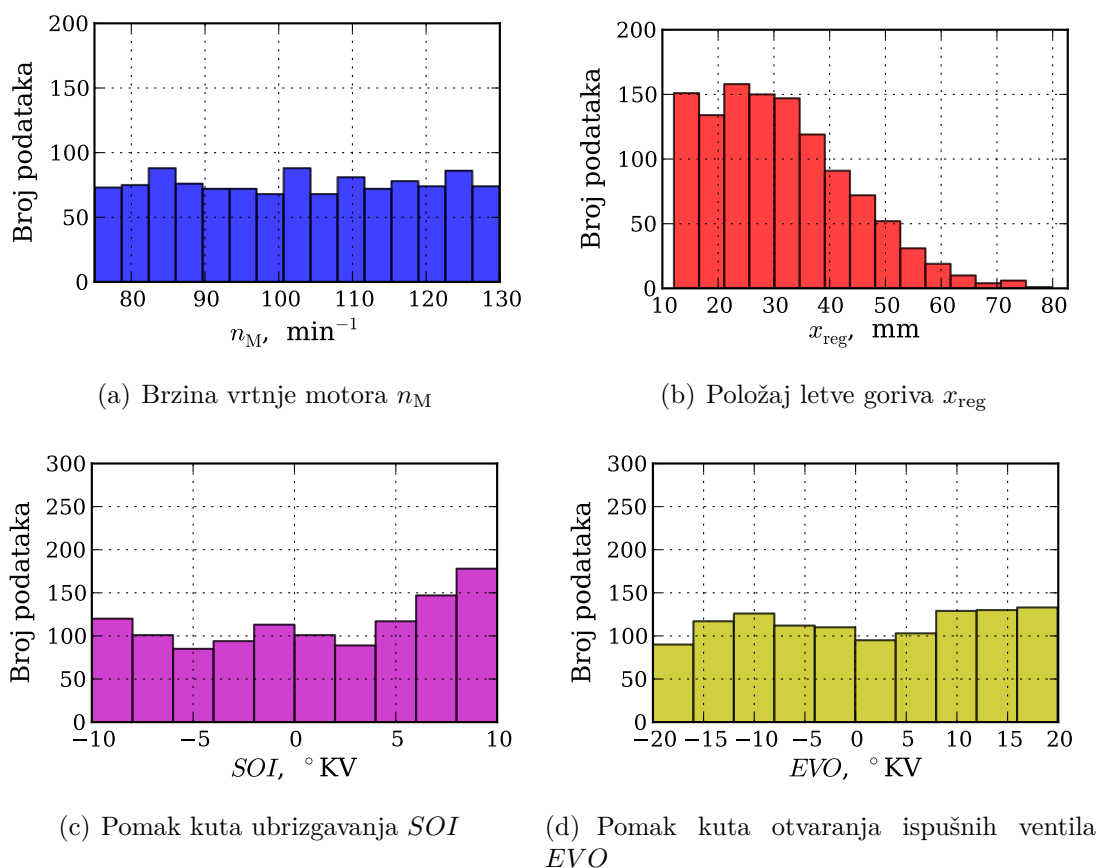
Analizirane su i promjene ostalih vrijednosti izlaznih varijabli po procesima i vidjelo se da je za njihovu konvergenciju dovoljan uvjet konvergencije specifične potrošnje goriva.

Na histogramima podataka za koje je proračun 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 je veći broj podataka koji su konvergirali za ulazne vrijednosti položaja letve goriva većim od 40 mm i da je broj podataka sve veći do položaja letve goriva od 65 mm. Razlog tome je zahtjev za minimalnom količinom goriva potrebnom za stabilni rad turbopuhala koji nije zadovoljen za niže vrijednosti položaja letve goriva (minimalni položaj ovisan je i o preostalim ulaznim parametrima vrijednosti brzine vrtnje motora,

pomaku kuta ubrizgavanja kao i pomaku kuta otvaranja ispušnih ventila). Kod viših količina goriva rad je bio još stabilniji čak i pri promjeni kuta početka 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 letve goriva odabrana je vrijednost od 12 mm za ovaj motor. To je njen najniži mogući fizički položaj.

Pri nižim položajima letve, 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* (engl. *Start of Injection*). Pri pomaku kuta početka ubrizgavanja na kasnije, izgaranje u cilindru motora kasni i smanjuje se rad dobiven ekspanzijom, pa se u tom slučaju snaga motora se 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 letve 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 5.4(b).

Podaci numeričkih simulacija koji nisu uspjeli konvergirati, a koji su ovdje nazvani "divergirajući" odnose se na one ulazne podatke za koje simulacija nije uspjela postići

stabilnu radnu točku (tj. nije došlo do konvergencije, kriterij konvergencije opisan je pod 5.2.2). Razlog tome mogu biti razlike između realnog sustava i korištenog numeričkog modela za simulacije (matematički model podrazumijeva pojednostavljenja) kao i sama nestabilnost dinamičkih komponenti sustava koji čine brodski dvotaktni dizelski motor za zadane ulazne vrijednosti. Takve situacije pojavljuju se u slučajevima kada turbopuhalo ispada iz pogona zbog narušene bilance energije između turbine i puhala, čime se prekida ispiranje motora koje je nužno potrebno za rad motora. 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

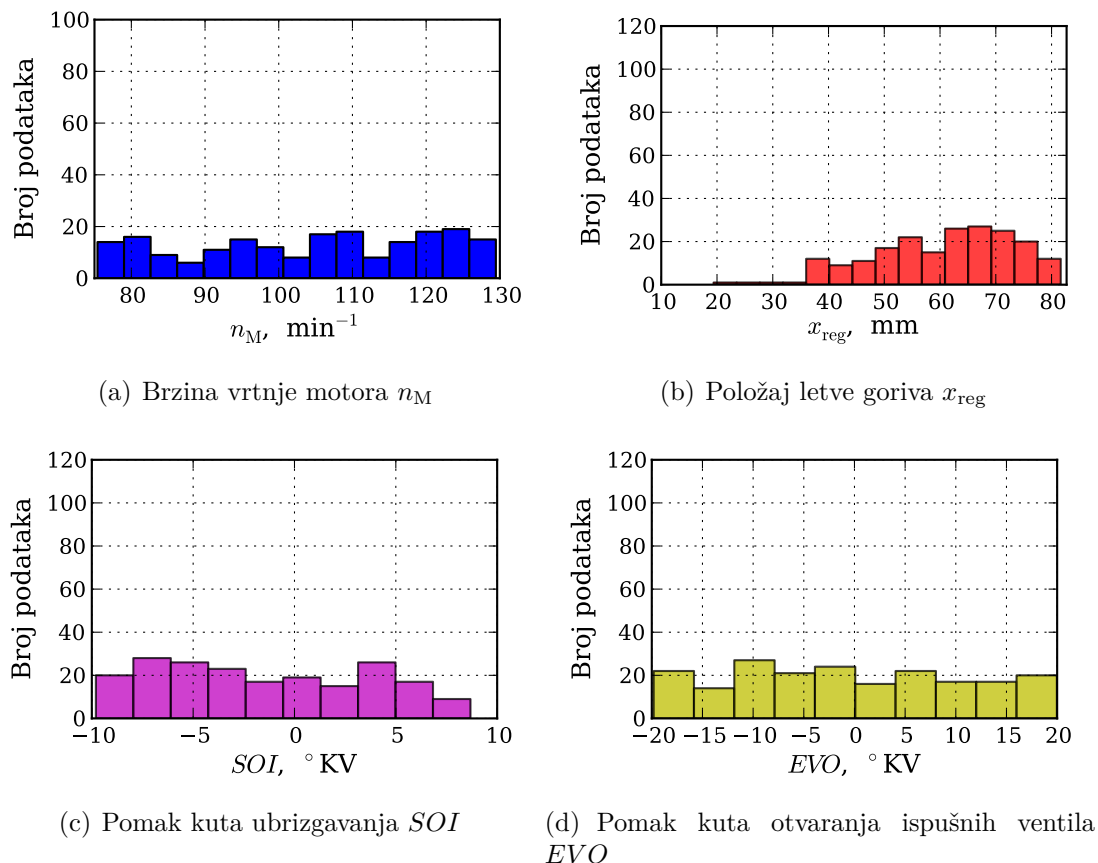


Slika 5.6: Histogrami ulaznih podataka za treniranje mreže

Histogrami ulaznih podataka za treniranje predstavljaju distribuciju ulaznih vrijednosti u setu podataka za treniranje. Svaka ulazna varijable mora imati podjednaku zastupljenost ulaznih vrijednosti po pojedinim segmentima u čitavom području za koje je definirana. To nije slučaj za x_{reg} , pa je tu moguće veća pogreška učenja za vrijednosti u onim segmentima u kojima je manji broj podataka.

Set za treniranje pokazuje da postoji nesrazmjernost u distribuciji podataka za položaj letve goriva (zbog konvergencije). Nije izvršena korekcija, pa je to utjecalo na nešto veću pogrešku izlaznih vrijednosti za one podatke kojima je ulazna vrijednost x_{reg} u onom segmentu koji ima manji broj podataka.

5.4 Histogrami ulaznih podataka za validaciju mreže

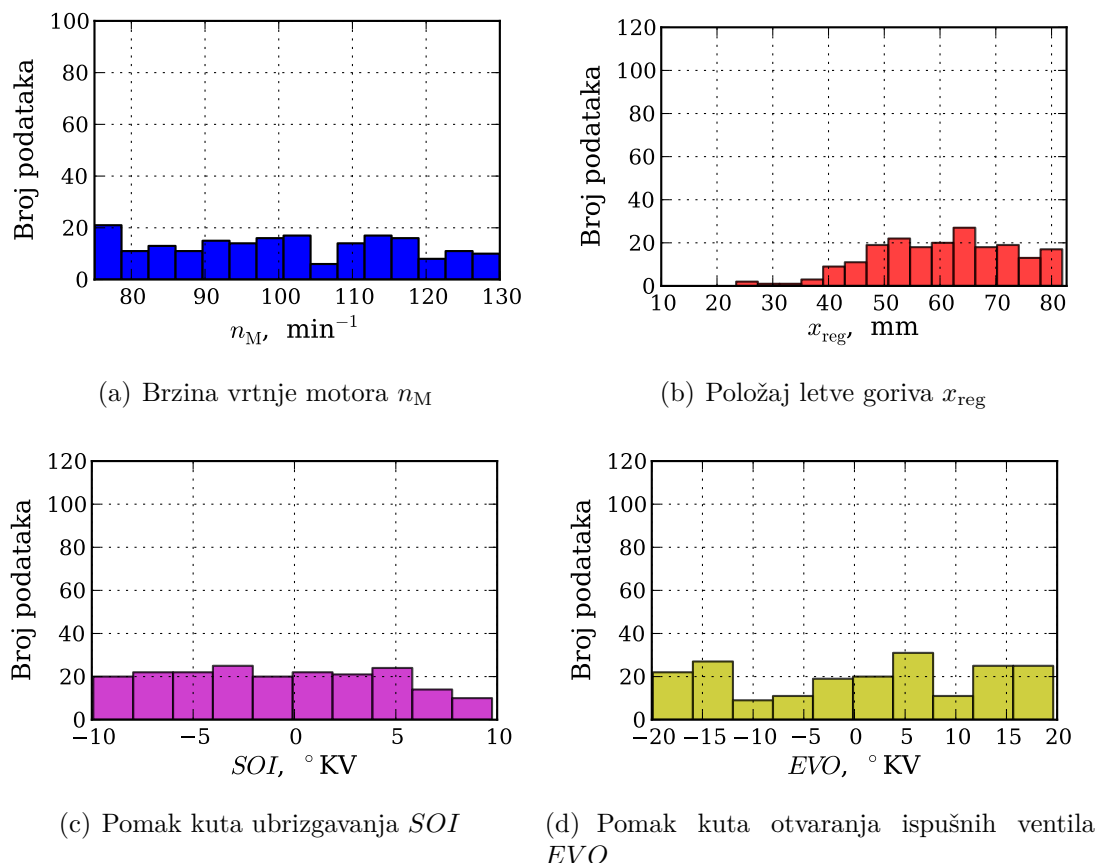


Slika 5.7: Histogrami ulaznih podataka za validaciju mreže

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 apsolutni broj podataka po pojedinom segmentu vrijednosti.

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 uvjet. Za konačni test poželjno je imati što različitiye podatke od onih s kojima je mreža trenirana, čime se provjerava generalizacija na nevidenim podacima. U simulacijama se koristio set podataka za validaciju kao uvjet za prekid učenja mreže, stoga je bilo potrebno izvršiti dodatnu validaciju mreže s 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 koristila pri učenju je snaga, jer se jednostavno može izračunati iz momenta. Lambda je korištena prilikom učenja, ali se u eksploataciji 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 (slika 5.9). Set podataka za treniranje, validaciju i test bio je podijeljen u omjeru približno 70%-15%-15%.

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. Iz više pokušaja učenja na podacima seta za treniranje i s različitim početnim težinama, pokazalo se da je broj potrebnih neurona između 20 i 40. Kod mreža s većim brojem neurona (više od 40) nastaje problem ulaska u lokalni minimum i izrazito spore konvergencije. 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 tablici 5.4 dan je prikaz relativnih

pogreški po pojedinoj ulaznoj varijabli. U konačnici, pogreška na setu podataka za konačni test bila je najveća, ali ne značajno veća od pogreške na setu za validaciju. Nakon što se pokazalo da u većini slučajeva 40 skrivenih neurona daje najbolje rezultate, ponovilo se učenje s 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.

Pokušavalo se odabrati optimalni set inicijalnih koeficijenata težina i primjenom genetskog algoritma (GA). Po iskustvu autora, traženje težina primjenom GA je efikasno samo ako neuronska mreža ima manji broj skrivenih neurona. Za veći broj skrivenih neurona optimizacija primjenom GA postala je vremenski i računski suviše opsežan posao.



Slika 5.9: Prikaz strukture korištene MLP mreže

5.7 Pregled rezultata i provjera pogreške

5.7.1 Usporedba vrijednosti simulacijskih podataka i podataka dobivenih neuronskom mrežom

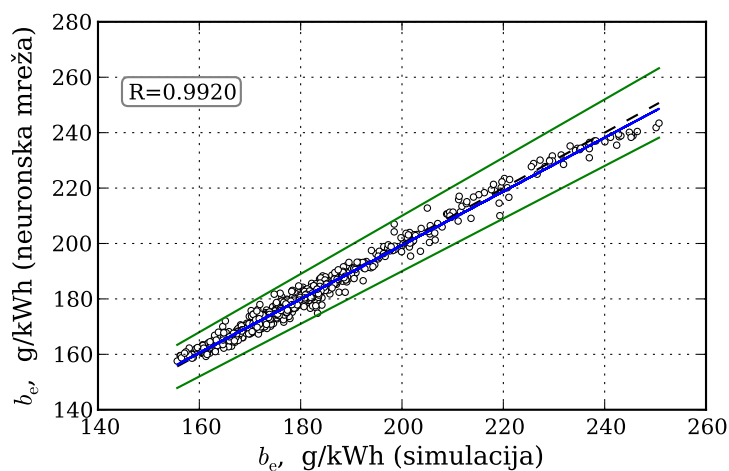
Pošto je nezahvalno uspoređivanje relativne pogreške na podacima koji su skalirani i obrađeni, prikaz razlike između podataka iz simulacije i podataka dobivenih iz neuronskih mreža dan je u originalnoj skali. Pri tome treba napomenuti da je napravljen izuzetak u prikazu temperatura, koje su originalno 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 s °C prikazuju nešto veću pogrešku nego u skali sa stupnjevima K.

	Podaci za treniranje (broj podataka)					Podaci za validaciju (broj podataka)				
	<5%	<10%	<15%	≥ 15%	Σ	<5%	<10%	<15%	≥ 15%	Σ
M_M	783 (96,7%)	23	3	0	809	190 (95,0%)	10	0	0	200
b_e	809 (100%)	0	0	0	809	200 (100%)	0	0	0	200
T_{IK}	784 (96,9%)	21	3	1	809	190 (95,0%)	10	0	0	200
$T_{izl,T}$	772 (95,4%)	28	7	2	809	181 (90,5%)	18	1	0	200
T_{UK}	785 (97,0%)	22	2	0	809	196 (98,0%)	4	0	0	200
$m_{prot,T}$	765 (94,5%)	37	6	1	809	188 (94,0%)	12	0	0	200
p_{UK}	803 (99,3%)	6	0	0	809	200 (100%)	0	0	0	200
p_{IK}	806 (99,6%)	3	0	0	809	199 (99,5%)	1	0	0	200
n_{TP}	797 (98,5%)	11	0	1	809	199 (99,5%)	1	0	0	200
$m_{prot,P}$	775 (95,8%)	30	3	1	809	192 (96,0%)	8	0	0	200
p_{max}	760 (93,9%)	49	0	0	809	186 (93,0%)	13	1	0	200
T_{max}	804 (99,4%)	5	0	0	809	199 (99,5%)	1	0	0	200


Tablica 5.4: Pregled relativne pogreške pojedine izlazne varijable (između tražene vrijednosti i one koja se dobila neuronskom mrežom kod skupa podataka za učenje i skupa podataka za validaciju)

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 isprekidanoj liniji su točne točke. Gornja zelena crta označava relativnu pogrešku od +5%, a donja zelena linija pogrešku od -5%. Plava crta označava regresijski pravac pogreške. Što su razlike između plave crte i isprekidane manje tj. odstupanja u donjem lijevom i gornjem desnom kutu manja to su i odstupanja manja. To svojstvo prikazano je pomoću koeficijenta korelacije R. Na svakom grafu prikazana je i vrijednost korelacije. Za svaki $R > 0.7$ može se reći da postoji visoka ili vrlo visoka matematička povezanost. U ovom slučaju povezanost između podataka iz simulacija provedenih za učenje i validaciju mreže i podataka dobivenih iz naučene mreže.

5.7.1.1 Usporedba vrijednosti specifične potrošnje b_e iz simulacije i dobivene neuronskom mrežom



(a) Podaci za treniranje




(b) Podaci za validaciju


Slika 5.10: Specifična potrošnja goriva, usporedba simulacije i neuronske mreže

Na slici 5.10 prikazano je odstupanje između vrijednosti specifičnih potrošnja goriva b_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 u potpunosti u području od $\pm 5\%$ relativne pogreške (potrebno je pogledati centar kruga).

5.7.1.2 Usporedba vrijednosti zakretnog momenta na motoru M_M iz simulacije i dobivene neuronskom mrežom



(a) Podaci za treniranje




(b) Podaci za validaciju


Slika 5.11: Zakretni moment na motoru, usporedba simulacije i neuronske mreže

Na slici 5.11 prikazana je pogreška između zakretnih momenata na motoru M_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 vrijednosti brzine vrtnje turbopuhala n_{TP} iz simulacije i dobivene neuronskom mrežom



(a) Podaci za treniranje




(b) Podaci za validaciju


Slika 5.12: Brzina vrtnje turbopuhala, usporedba simulacije i neuronske mreže

Slika 5.12 pokazuje da su uglavnom sve dobivene točke unutar reda točnosti kao i ostali ranije uspoređeni podaci. Na slici 5.12(a) vidi se da nekoliko točaka ne zadovoljava tražene uvjete točnosti. Naknadnom provjerom utvrđeno je da se te točke odnose na situacije s malim hodom letve 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 $m_{\text{prot,P}}$ iz simulacije i dobiven neuronskom mrežom



(a) Podaci za treniranje




(b) Podaci za validaciju


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

Slika 5.13 pokazuje da su uglavnom sve dobivene točke unutar reda točnosti kao i ostali ranije uspoređeni podaci.

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



(a) Podaci za treniranje




(b) Podaci za validaciju


Slika 5.14: Maseni protok na turbini, usporedba simulacije i neuronske mreže

Iz slike 5.14 vidi se dobro poklapanje podataka neuronske mreže i podataka iz simulacija. Iz usporedbe slika 5.13(a) i 5.14(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 5.15(a) i 5.16(a).

5.7.1.6 Tlak u usisnom kolektoru p_{UK} iz simulacije i dobiven neuronskom mrežom



(a) Podaci za treniranje




(b) Podaci za validaciju


Slika 5.15: Tlak u usisnom 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.

5.7.1.7 Tlak u ispušnom kolektoru p_{IK} iz simulacije i dobiven neuronskom mrežom



(a) Podaci za treniranje




(b) Podaci za validaciju

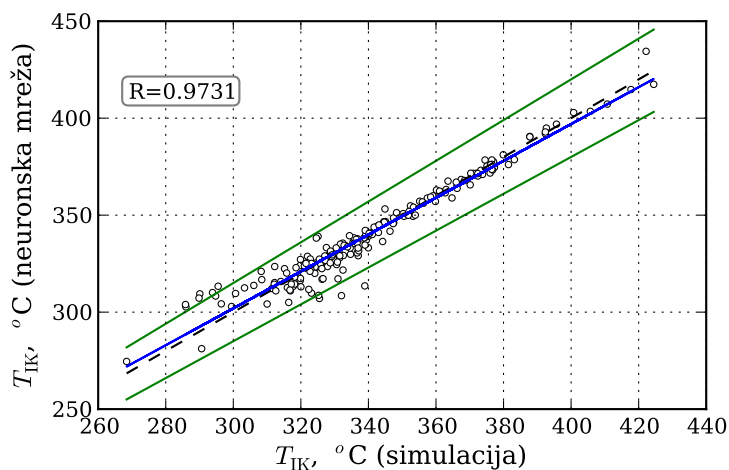
Slika 5.16: Tlak u ispušnom kolektoru, usporedba simulacije i neuronske mreže

Svi podaci su većinom unutar dopuštenih odstupanja, osim dvije točke na slici 5.16(a), o čemu je rečeno u poglavlju 5.7.1.5.

5.7.1.8 Temperatura u ispušnom kolektoru T_{IK} iz simulacije i dobivena neuronskom mrežom



(a) Podaci za treniranje




(b) Podaci za validaciju


Slika 5.17: 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 kolektoru T_{UK} iz simulacije i dobivena neuronskom mrežom



(a) Podaci za treniranje




(b) Podaci za validaciju


Slika 5.18: Temperatura u usisnom kolektoru, usporedba simulacije i neuronske mreže

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

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



(a) Podaci za treniranje




(b) Podaci za validaciju


Slika 5.19: Maksimalni tlak procesa, usporedba simulacije i neuronske mreže

Iz slike 5.19 je vidljivo da su poklapanja podataka unutar dopuštenih odstupanja.

5.7.1.11 Temperatura na izlazu it turbine $T_{izl,T}$ iz simulacije i dobivena neuronskom mrežom



(a) Podaci za treniranje




(b) Podaci za validaciju


Slika 5.20: Temperatura na izlazu iz turbine, usporedba simulacije i neuronske mreže

Iz slike 5.20 vide se značajnija odstupanja neuronske mreže i rezultata simulacija. Iz slike 5.20(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 5.20(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 procesa T_{\max} iz simulacije i dobivena neuronskom mrežom



(a) Podaci za treniranje



(b) Podaci za validaciju

Slika 5.21: Maksimalna temperatura procesa, usporedba simulacije i neuronske mreže

Podaci na slici 5.21 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_{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 prihvatanje novih podataka izmjenjenih tijekom eksploatacije motora. Očekuje se da će se učenjem mreže na dodatnim podacima iz eksploatacije motora, popraviti kvaliteta rezultata neuronske mreže. Prvim usporedbama izmjenjenih podataka i podataka neuronske mreže moći će se ocjeniti kvaliteta izmjenjenih 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 točnošću. Postignuti rezultati upućuju na mogućnost pouzdane primjene takve neuronske mreže u sustavima regulacije motora.


5.8 Primjer vrijednosti neuronske mreže za puno opterećenje motora

Opterećenje motora	25%	50%	75%	93,5%	100%	110%
Indicirana snaga (kW)	2401	4406	6580	8170	8656	9499
Efektivna snaga (kW)	2142	4099	6160	7667	8152	9014
Brzina vrtnje (min^{-1})	76,5	96	110,4	118,5	121,4	125,2
Hod letve goriva (mm)	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	39,7	50,3	63,3	73	75	81,8
Tlak ispirnog kolektora (bar)	1,39	2,03	2,76	3,33	3,55	3,93
Temperatura u ispirnom kolektoru ($^{\circ}\text{C}$)	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 ($^{\circ}\text{C}$)	308	327	346	384	404	458
Brzina vrtnje turbopuhala (min^{-1})	7290	11360	13870	15360	15895	17110
Specifična potrošnja goriva (g/kWh)	186,83	174,06	171,18	171,82	174,66	/

Tablica 5.5: Podaci mjerenja na ispitnom stolu [81]


Sukladno podacima mjerenja motora na ispitnom stolu, puno opterećenje motora postiže se pri brzini vrtnje $n_M = 121.4 \text{ min}^{-1}$ i položaju letve goriva na $x_{\text{reg}} = 75 \text{ mm}$. U tablici 5.5 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 ispitnog 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 5.23 vidi se utjecaj pomicanja početka ubrizgavanja goriva i otvaranja ispušnog ventila. Vidljiv je vrlo slab 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: Snaga motora P_{ef} , MW;

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




Slika 5.23: Zakretni moment motora M_M , kNm




Slika 5.24: Specifična potrošnja goriva b_e , g/kWh

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.




Slika 5.25: Tlak u ispušnom kolektoru P_{IK} , MPa

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 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 5.26: Temperatura u ispušnom kolektoru T_{ik} , °C

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




Slika 5.27: Brzina vrtnje turbopuhala $n_{TP}/1000$, min^{-1}




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

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 otpadne topline motora. Obzirom na relativno veliki dio zraka za ispiranje, koji samo projuri kroz cilindar i dopiye 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 5.22 je vidljivo vrlo blago smanjenje snage motora pri kasnijem otvaranju ispušnog ventila.



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




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


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 slično 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 postizemo 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 5.31: Tlak u usisnom kolektoru P_{UK} , MPa



Slika 5.32: Temperatura u usisnom kolektoru T_{UK} , °C




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



Slika 5.34: Maksimalna temperatura u cilindru motora T_{\max} , °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 s 50% opterećenja. Te se slike mogu usporediti s 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_e , g/kWh




Slika 5.37: Maseni protok na turbini $m_{prot,T}$, 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_{\max} , °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 osigurali minimalni uvjeti za ispiranje cilindara motora. U ovom radu nije istraživani 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 rješenja za *SOI* i *IVO* pretraživano je u diskretnom koraku od $0,5^\circ\text{KV}$. Prilikom traženja optimalnih uvjeta za potrebe utilizacije otpadnih toplina potrebno je poznavati kretanje parametara koji utječu na toplinsku snagu iza turbine. Za zadanu brzinu vrtnje motora n_M i položaj letve goriva x_{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_e , maksimalnom tlaku p_{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_M , i sl.) donosi se odluka o režimu rada koji će se odabrati. Primarni cilj je dobivanje dovoljne toplinske snage kako bi se mogao izvršiti proces utilizacije topline ispušnih plinova motora.

6.1 Upravljanje početkom ubrizgavanja goriva i otvaranja ispušnog ventila s ciljem postizanja maksimalne toplinske snage ispušnih plinova

Za određenu brzinu vrtnje motora i položaj letve goriva potrebno je pronaći *SOI* i *EVO* s kojima se postiže najveći toplinski tok ispušnih plinova. U tablici su dani podaci (za zadani $n_M = 118.5$ i $x_{\text{reg}} = 73$) 6.1 za referentnu toplinsku snagu izračunatu za $SOI = 0$ i $EVO = 0$, te optimalni pomaci za postizanje najveće toplinske snage ispušnih plinova.

<i>SOI</i> , °KV	<i>EVO</i> , °KV	b_e , g/kWh	M_M , kNm	P_{ef} , MW	T_{max} , °C	p_{max} , MPa	Q , kW	%
0	0	173	617,77	7,67	1551,4	14,5	3987,9	100%
+3,5	+20	184,7	576,45	7,15	1363,8	15,55	4366,2	109,5%


Tablica 6.1: Maksimiziranje toplinskog toka

Slučaj u kojem je postignuta najveća toplinska snaga uspoređen je s 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 $3,5^\circ\text{KV}$ 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 u ovisnosti o *SOI* i *EVO*




Slika 6.2: Specifična potrošnja goriva b_e , g/kWh u ovisnosti o *SOI* i *EVO*



Slika 6.3: Maksimalni tlak procesa p_{\max} , MPa u ovisnosti o SOI i EVO



Slika 6.4: Maksimalna temperatura procesa T_{\max} , $^{\circ}C$ u ovisnosti o SOI i EVO



Slika 6.5: Zakretni moment motora M_{mot} , kNm u ovisnosti o SOI i EVO

6.2 Zadovoljavanje potrebne toplinske snage uz zadržavanje konstantnog zakretnog momenta i brzine vrtnje motora

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 $M_M = 465 \text{ kNm}$. Zadana je i minimalna potrebna toplinska snaga iza turbine $Q_{\min} = 3200 \text{ kW}$. Isto tako, zadani su limiti na ručicu između vrijednosti 40 i 75 mm. Postavljena su i ograničenja najveće maksimalne temperature u cilindru $T_{\max, \lim} = 1900^\circ \text{C}$ i najveći dopušteni maksimalni tlak procesa u cilindru $p_{\max, \lim} = 40 \text{ MPa}$.

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 *EVO*, 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. Zakretni moment na motoru M_M , kNm u ovisnosti o *SOI* i *EVO* je gotovo konstantan, ali u nekim kombinacijama ne može se održati. 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.

<i>SOI</i> °KV	<i>EVO</i> °KV	M_M kNm	b_e g/kWh	x_{reg} mm	P_{ef} MW	T_{max} °C	p_{max} MPa	Q 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 $n_M = 118.5 \text{ min}^{-1}$ i $M_M = 465 \text{ kNm}$


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 ($n_M = 118,5 \text{ min}^{-1}$ i $M_M = 465 \text{ kNm}$). 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 ima manju specifičnu potrošnju od prethodne. Ako je najmanje jedna točka zadovoljila sve navedene uvjete, sustav ima rješenje. Na sljedećim slikama prikazana su polja traženih vrijednosti za zadani zakretni moment motora M_M .

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




Slika 6.6: Zakretni moment na motoru M_M , kNm u ovisnosti o SOI i EVO

Bitno je primjetiti (slika 6.7) da je za uvijet zadržavanja zakretnog momenta motora bitno uz promjene SOI i IVO potrebno vršiti i korekciju pomaka letve goriva.




Slika 6.7: Pomak letve goriva x_{xreg} , mm s ciljem održavanje momenta u ovisnosti o SOI i EVO




Slika 6.8: Specifična potrošnja goriva b_e , g/kWh u ovisnosti o SOI i EVO

Na slici 6.8 vidi se da je najmanja specifična potrošnja u području referentnih pomaka SOI i EVO , ali u tom području nije i najveća toplina dostupna za potrebe utilizacije. Iz slike 6.9 vidi se da pomaci SOI i EVO na kasnije od referentnih vrijednosti povećavaju toplinu dostupnu na izlazu iz turbine.




Slika 6.9: Toplina dostupna na izlazu iz turbine Q , kW u ovisnosti o SOI i EVO



Slika 6.10: Maksimalni tlak procesa p_{\max} , MPa u ovisnosti o SOI i EVO

Na slikama 6.10 i 6.10 vidljivo je da su zadovoljeni i uvjeti maksimalnog tlaka i maksimalne temperature procesa u cilindru za cijelo promatrano područje SOI i EVO .



Slika 6.11: Maksimalna temperatura procesa T_{\max} , $^{\circ}C$ u ovisnosti o SOI i EVO

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 postizemo minimalnu specifičnu potrošnju goriva. Na taj način dovodimo motor u područje optimalnoga rada za zadanu dopuštenu maksimalnu temperaturu procesa. U tablici 6.3 navedeni su 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 referentno 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	$T_{\max, \text{limit}}$ °C	SOI	EVO	b_e , g/kWh	T_{\max}	$b_{e, \text{ref}}$, g/kWh	$T_{\max, \text{ref}}$ °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

Tablica 6.3: 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

Kompleksnost dinamičkog modela brodskoga dizelskog motora potaknula je izradu jednostavnijeg modela koji koristi MLP neuronsku mrežu. Model koji koristi neuronsku mrežu poslužio je bržoj analizi podataka s ciljem postizanja određenih performansi rada motora koje je bi inače teže postigli s klasičnim modelima. Analiza rada motora podrazumjeva poznavanje podataka u svim režimima rada, što za provođenje potrebnih proračuna iziskuje velike resurse u vremenu i računalnoj opremi.

U ovom radu analiza se ograničila na stacionarna stanja rada brodskog dizelskog motora, a promatrani ulazni parametri su: brzina vrtnje motora, položaj letve goriva kao i pomak početka ubrizgavanja goriva te pomak otvaranja ispušnog ventila. Pomaci su relativni u odnosu na referentne određene od strane proizvođača.

Za postizanje stacionarnog stanja prilikom mjerenja potrebno je postupno dovoditi motor u stacionarnu radnu točku, za što je potrebno određeno vrijeme i potrošnja goriva. I kod klasičnih simulacija motor se postupno dovodi u stacionarno stanje, a vrijeme potrebno za postizanje stacionarno stanje kod numeričkih simulacija zna biti i višestruko duže nego kod realnog motora. Kod ovog modela s neuronskom mrežom za učenje bitna su samo stacionarna stanja, a naučeni model može brzo davati vrijednosti ali samo za stacionarna stanja.

Model baziran na neuronskoj mreži razvijen je temeljen podataka dobivenih iz klasičnih simulacija i to za stacionarna stanja uz provjeru istih podataka s dostupnim izmjenim vrijednostima sa ispitnog stola. Stoga je postojanje kvalitetnog klasičnog modela u fazi razvoja neuronske mreže neupitno. Isto tako, model dobivene neuronske mreže ima ograničenja na koja treba pripaziti (npr. model vrijedi za stacionarna stanja, za istu vrstu motora, za isto odabrano turbopuhalo i sl., ali dobivena struktura može efikasno učiti i na podacima za novi tip motora).

Podaci za učenje i testiranje neuronske mreže moraju biti unutar svih radnih stacionarnih režima rada motora. 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 pri optimizaciji 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 slo-

ženiji od sustava regulacije klasičnih motora koji nemaju 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.

Za potrebe učenja neuronske mreže provedene su numeričke simulacije za dvotaktne brodske dizelske motore u širem rasponu područja rada. Obzirom da ti motori koriste prednabijanje turbopuhalom, kriterij za njihov sigurni rad je u tome da je tlak zraka u usisnom kolektoru viši od tlaka u ispušnom kolektoru, kako bi se moglo odvijati ispiranje motora radi izmjene radnoga medija. Uvjeti rada turbopuhala su takvi da ono nije u stanju zadovoljiti takve potrebe motora, posebno pri niskim brzinama vrtnje i niskim opterećenjima. U takvim slučajevima se u normalnoj eksploataciji motora uključuju ventilatori pogonjeni elektromotorom. U ovom istraživanju nije uzeta u obzir ta mogućnost, obzirom da je takav rad motora ograničen u svom trajanju. Rezultati numeričkih simulacija su ukazali na nemogućnost rada turbopuhala i motora u tim graničnim uvjetima, što se može vidjeti na prikazanim slikama. Primijenjeni model za numeričke simulacije nije prilagođen za rubne uvjete rada turbopuhala, kao što je na primjer "pumpanje" puhala, tako da su donekle upitni rezultati modela pri takvom radu. Motor veći dio vremena radi u područjima stabilnog rada izvan tih graničnih područja. To je vjerojatno bio uzrok povećanih odstupanja pri učenju mreže.

Točnost rezultata numeričkih simulacija za glavno područje rada, pri čemu motor zajedno s turbopuhalom radi u stabilnim uvjetima, dovoljno je visoka da te rezultate koristimo za učenje neuronske mreže. U radu je prikazana usporedba rezultata numeričkih simulacija s dostupnim izmjerenim vrijednostima za karakteristike motora na ispitnom stolu. To je bio dovoljan uvjet da rezultate numeričkih simulacija koristimo za učenje neuronske mreže, u nedostatku većeg paketa izmjerenih podataka na motoru.

Primjena klasične strukturirane mreže za razdiobu radnih točki za uvjete rada motora može prouzročiti problematične prognoze naučene neuronske mreže zbog utjecaja smjera prilaza radnoj točki pri konvergenciji rezultata za zadanu točku. Odabirom slučajne razdiobe radnih točaka dobiva se bolje pokrivanje cijelog područja rada motora s manjim brojem podataka. Takvim vođenjem numeričkih simulacija dobiveni su mnogo kvalitetniji podaci za učenje.

Kako unaprijed nisu bile poznate vrijednosti maksimalnoga momenta kojega može dati motor, korišteno je ubrizgavanje promjenjive količine goriva (neovisno o regulatoru) pri različitim brzinama vrtnje motora. Pogodnost ovoga pristupa je bila u tome da se izbjegne dvojnost podataka. Pokazalo se je da za isti maksimalni moment možemo imati različite količine ubrizganoga goriva ovisno o početku ubrizgavanja goriva i otvaranja ispušnog ventila. Za uvid u jednodimenzionalnost podataka korišteni su grafovi koji prikazuju broj ponavljanja skupova ulaznih podataka. Pokazalo se da je razdioba skupova jednolika, osim za one grupe ulaznih vrijednosti za koje turbopuhalo ne može zadovoljiti. Jednodimenzionalnost distribucije podjednaka je i na podacima koji su se koristili za učenje mreže, kao i na podacima za validaciju.

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.

Namjera prikazanih istraživanja bila je u izradi modela neuronskih mreža za implementaciju u suvremenim inteligentnim sustavima vođenja glavnoga brodskog dizelskog motora. Time će se omogućiti gotovo trenutna prognoza parametara rada motora za željenu kombinaciju ulaznih podataka. Ova prognoza će moći isto tako pravovremeno dati podatak da li ulazimo u neprihvatljiva područja rada motora, tako da se posadi ostavlja dovoljno vremena za odgovarajuću reakciju.

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 u radne uvjete za potrebe utilizacije otpadne topline, uz minimalnu specifičnu potrošnju goriva na motoru, te za optimizaciju maksimalne temperature procesa motora u svrhu smanjenja emisija NO_x -a.

Razvijeni model neuronske mreže u potpunosti je pripremljen za prihvatanje novih podataka, izmjerenih tijekom eksploatacije motora. Prvim usporedbama izmjerenih podataka i podataka neuronske mreže moći će se ocijeniti 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.

Popis literature

- [1] Radica, G. *Ekspertni sustav za dijagnostiku stanja i optimiranje rada brodskog diesellovog 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] Antičić, R., Munitić, A., and Vukić, Z. 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] Antičić, 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] Arcaklioglu, 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 Boržiková, 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*, 2009.
- [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 Verbrennungskraftmaschine*. 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 Papadopoulos, S. Zur modellbildung des motorischen verbrennungsablaufes. *MTZ*, 45(1):21–26, 1984.
- [65] Sitkei, G. Über den dieselmotorischen zündverzug. *MTZ*, 24(6):190–194, 1963.
- [66] Betz, A. and Woschni, G. Umsetzungsgrad und brennverlauf aufgeladener dieselmotoren im instationären 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, Arbeitsweise, Aufbau und Berechnung von Zweitakt und Viertakt Motoren*, volume 47. Vogel Verlag, 6. Auflage, Würzburg,, 1982.
- [70] Sher, E. and Harari, R. A. A simple and realistic model for the scavenging process in a crankcase 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 mittelschnelllaufenden 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] Račić, N. *Simulacija rada brodskog propulzijskog sustava sa sporohodnim dizelskim motorom u otežanim uvjetima*. PhD thesis, 2008.
- [82] Taylor, B. J. *Methods and Procedures for the Verification and Validation of Artificial Neural Networks*. Springer Science+Business Media, Inc, 2006.

Popis oznaka i simbola

OZNAKA	JEDINICA	NAZIV
A	m^2	površina
b_e	g/kWh	specifična potrošnja goriva
c_m	m/s	srednja stapna brzina
c_0	m/s	teoretska brzina strujanja
c_p	$J/(kg\ K)$	specifični toplinski kapacitet pri $p = \text{const}$
d	m	promjer
E	J	energija
EVO	$^\circ$	kut pomaka otvaranja ispušnih ventila
F	N	sila
h	J/kg	specifična entalpija
h	m	podizaj, hod ventila, visina
H_d	J/kg	donja ogrjevna moć goriva
J	$kg\ m^2$	moment tromosti
K_p	-	faktor proporcionalnosti
k	W/m	toplinska vodljivost
l	m	duljina ojnice
L	m	dužina
L_{st}	kg	masa zraka za stehiometrijsko izgaranje goriva
m	kg	masa
m	-	Vibeov eksponent
\dot{m}	kg/s	maseni protok
M	Nm	moment
n	min^{-1}	brzina vrtnje
p	Pa	tlak
P	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	$^\circ$	kut pomaka početka ubrizgavanja goriva
t	s	vrijeme

T	K	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_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

Grčka slova

SIMBOL	JEDINICA	NAZIV
α	W/(m ² ·K)	koeficijent prijelaza topline
α	-	koeficijent protoka
β	-	stupanj čistoće plinova
β	°	kut između ojnice i osi cilindra
ε	-	geometrijski stupanj kompresije
η	-	stupanj djelovanja
η	Ns/m ²	dinamička viskoznost
η_L	-	stupanj punjenja
η_S	-	potpunost ispiranja
φ	°	kut zakreta osnog koljena
κ	-	eksponent adijabate
λ	-	pretičak zraka
λ	W/(m K)	toplinska vodljivost
λ_m	-	omjer r/l polužja koljenastog mehanizma
λ_A	-	stupanj dobave
μ	-	faktor trenja
ν	-	bezdimenzijska značajka brzine
π	-	omjer tlakova
ϱ	kg/m ³	gustoća
τ	-	taktnost motora (2 ili 4)
ψ	-	funkcija protjecanja

Indeksi

INDEKS	TUMAČENJE
0	nazivna veličina
atm	atmosfera
c	cilindar
cjg	cjevovod goriva
dz	dodatni zrak
ef	efektivno
g	gorivo
geom	geometrijski
HZ	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
M	motor
max	maksimalni
meh	mehanički
min	minimalni
nP	nakon puhala
nT	nakon turbine
p	ukupni broj ulaza u neuron, indeks
P	puhalo
PI	početak izgaranja
PD	početak dobave goriva
Pot	potrošač
pP	prije puhala
pr	proces, propušteno
prot	protok
pT	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
T	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]	7
3.2	Kontrolni volumen cilindra motora [2]	10
3.3	Udio izgorenog goriva i brzina izgaranja prema Vibeu	13
3.4	Model potpunog miješanja	19
3.5	Promjena potpunosti ispiranja, odstupnja punjenja i čistoće plinova u ovisnosti o stupnju dobave	20
3.6	Usisni kolektor [2]	20
3.7	Bezdimenzijska promjena temperature zraka za unakrsni izmjenjivač topline	22
3.8	Ispušni kolektor [2]	23
3.9	Turbopuhalo	24
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	26
3.13	Visokotlačna pumpa goriva s VIT sustavom sporohodnog brodskog motora [78]	32
3.14	Djelovanje visokotlačne pumpe goriva s VIT funkcijom [78]	32
3.15	Ubrizgana masa goriva po procesu prikazana kao karakteristika visokotlačne pumpe goriva: a) ovisno o kutnoj brzini i b) ovisno o hodu letve goriva [2]	33
3.16	Dijagram toka signala za model brodskog dizelskog motora s prednabijanjem [2]	34
3.17	Proces izrade simulacijskog modela	35
3.18	Blok-shema simulacijskog modela brodskog propulzijskog sustava izvedena u Matlab-Simulink računalnoj aplikaciji [81]	36
4.1	Prikaz neurona s pragom	42
4.2	Prikaz neurona s dodatnom težinom umjesto praga	42
4.3	Logističke sigmoidne funkcije	43
4.4	Stepenaste sigmoidne funkcije	43
4.5	Funkcija hiperboličkog tangensa	44
4.6	Linearna funkcija	44
4.7	Funkcija praga	45
4.8	Limitirane linearne funkcije	45
4.9	Elliot funkcije	46
4.10	Gaussove funkcije	47
4.11	Prikaz slojeva MLP neuronske mreže	47
4.12	Rodvoldov model razvoja neuronske mreže [82]	49
4.13	Utjecaj brzine učenja na konvergenciju	52
5.1	Poprečni presjek dizelskog motora 6S50MC MAN&BW	56
5.2	Usporedba izmjerenih vrijednosti i rezultata simulacije u stacionarnim točkama, pri: 25%, 50%, 75%, 93,5%, 100% i 110% opterećenja motora [81]	57
5.3	Histogrami ulaznih podataka u simulacijama	60

5.4	Histogrami ulaznih simulacijskih podataka, konvergirajući	61
5.5	Histogrami ulaznih simulacijskih podataka, divergirajući	62
5.6	Histogrami ulaznih podataka za treniranje mreže	63
5.7	Histogrami ulaznih podataka za validaciju mreže	64
5.8	Histogrami ulaznih podataka za konačni test mreže (ocjenu nakon treniranja)	65
5.9	Prikaz strukture korištene MLP mreže	66
5.10	Specifična potrošnja goriva, usporedba simulacije i neuronske mreže . . .	68
5.11	Zakretni moment na motoru, usporedba simulacije i neuronske mreže . .	69
5.12	Brzina vrtnje turbopuhala, usporedba simulacije i neuronske mreže . . .	70
5.13	Maseni protok na puhalu, usporedba simulacije i neuronske mreže	71
5.14	Maseni protok na turbini, usporedba simulacije i neuronske mreže	72
5.15	Tlak u usisnom kolektoru, usporedba simulacije i neuronske mreže	73
5.16	Tlak u ispušnom kolektoru, usporedba simulacije i neuronske mreže . . .	74
5.17	Temperatura u ispušnom kolektoru, usporedba simulacije i neuronske mreže	75
5.18	Temperatura u usisnom kolektoru, usporedba simulacije i neuronske mreže	76
5.19	Maksimalni tlak procesa, usporedba simulacije i neuronske mreže	77
5.20	Temperatura na izlazu iz turbine, usporedba simulacije i neuronske mreže	78
5.21	Maksimalna temperatura procesa, usporedba simulacije i neuronske mreže	79
5.22	Snaga motora P_{ef} , MW;	81
5.23	Zakretni moment motora M_M , kNm	81
5.24	Specifična potrošnja goriva b_e , g/kWh	82
5.25	Tlak u ispušnom kolektoru P_{IK} , MPa	82
5.26	Temperatura u ispušnom kolektoru T_{IK} , °C	83
5.27	Brzina vrtnje turbopuhala $n_{TP}/1000$, min^{-1}	83
5.28	Temperatura iza turbine turbopuhala $T_{izl,T}$, °C	84
5.29	Maseni protok na turbini $m_{prot,T}$, kg/s	84
5.30	Toplinska snaga ispušnih plinova na izlazu iz turbine Q , kW	85
5.31	Tlak u usisnom kolektoru P_{UK} , MPa	86
5.32	Temperatura u usisnom kolektoru T_{UK} , °C	86
5.33	Maksimalni tlak u cilindru motora p_{max} , MPa	87
5.34	Maksimalna temperatura u cilindru motora T_{max} , °C	87
5.35	Snaga motora P_{ef} , MW;	88
5.36	Specifična potrošnja goriva b_e , g/kWh	89
5.37	Maseni protok na turbini $m_{prot,T}$, kg/s	89
5.38	Temperatura ispušnih plinova iza turbine $T_{izl,T}$, °C	90
5.39	Toplinska snaga ispušnih plinova na izlazu iz turbine Q , kW	90
5.40	Maksimalni tlak u cilindru motora p_{max} , MPa	91
5.41	Maksimalna temperatura u cilindru motora T_{max} , °C	91
6.1	Toplina dostupna na izlazu iz turbine Q , kW u ovisnosti o <i>SOI</i> i <i>EVO</i> .	94
6.2	Specifična potrošnja goriva b_e , g/kWh u ovisnosti o <i>SOI</i> i <i>EVO</i>	94
6.3	Maksimalni tlak procesa p_{max} , MPa u ovisnosti o <i>SOI</i> i <i>EVO</i>	95
6.4	Maksimalna temperatura procesa T_{max} , °C u ovisnosti o <i>SOI</i> i <i>EVO</i> . .	95
6.5	Zakretni moment motora M_{mot} , kNm u ovisnosti o <i>SOI</i> i <i>EVO</i>	96
6.6	Zakretni moment na motoru M_M , kNm u ovisnosti o <i>SOI</i> i <i>EVO</i>	98
6.7	Pomak letve goriva x_{xreg} , mm s ciljem održavanje momenta u ovisnosti o <i>SOI</i> i <i>EVO</i>	98
6.8	Specifična potrošnja goriva b_e , g/kWh u ovisnosti o <i>SOI</i> i <i>EVO</i>	99

6.9	Toplina dostupna na izlazu iz turbine Q , kW u ovisnosti o <i>SOI</i> i <i>EVO</i>	99
6.10	Maksimalni tlak procesa p_{\max} , MPa u ovisnosti o <i>SOI</i> i <i>EVO</i>	100
6.11	Maksimalna temperatura procesa T_{\max} , °C u ovisnosti o <i>SOI</i> i <i>EVO</i>	100

Popis tablica

5.1	Osnovni podaci analiziranog motora 6S50MC MAN&BW [81]	55
5.2	Raspon vrijednosti ulaznih parametara	59
5.3	Popis ulaznih i izlaznih varijabli korištenih za istraživanje	59
5.4	Pregled relativne pogreške pojedine izlazne varijable (između tražene vrijednosti i one koja se dobila neuronskom mrežom kod skupa podataka za učenje i skupa podataka za validaciju	67
5.5	Podaci mjerenja na ispitnom stolu [81]	80
6.1	Maksimiziranje toplinskog toka	93
6.2	Maksimiziranje toplinskog toka za zadani $n_M = 118.5 \text{ min}^{-1}$ i $M_M = 465 \text{ kNm}$	97
6.3	Rezultati optimizacije potrošnje goriva	101

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 gimnaziju, prirodoslovno-matematički smjer. Godine 1996. upisuje se na sveučilišni 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 Dynamax 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 sveučilišnoga 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.

PODACI O AUTORU I DOKTORSKOJ DISERTACIJI

1. AUTOR

Ime i prezime: Ozren Bukovac

Datum i mjesto rođenja: 13. ožujka 1978., Rijeka

Naziv fakulteta, smjera i godina završetka dodiplomskog studija: Sveučilište u Rijeci, Tehnički fakultet, 2002.

Naziv fakulteta, smjera i godina završetka poslijediplomskog studija: Sveučilište u Rijeci, Tehnički fakultet, 2009.

Sadašnje zaposlenje: Sveučilište u Rijeci, Tehnički fakultet

2. DOKTORSKA DISERTACIJA

Naslov: Predviđanje parametara rada brodskog dizelskog motora primjenom neuronskih mreža

Broj stranica, slika, tablica i bibliografskih podataka: 125, 83, 8, 86

Znanstveno polje i grana: Strojarsstvo, brodsko strojarstvo

Voditelj rada: Red. prof. dr. sc. Vladimir Medica, dipl. ing.

Fakultet na kojem je rad obranjen: Sveučilište u Rijeci, Tehnički fakultet

3. OBRANA I OCJENA

Datum prijave teme: 1. srpnja 2008.

Datum predaje rada: 17. travnja 2012.

Datum prihvaćanja ocjene rada: 19. srpnja 2012.

Sastav Povjerenstva za ocjenu: Red. prof. dr. sc. Zmagoslav Prelec, dipl. ing.
Red. prof. dr. sc. Vladimir Medica, dipl. ing.
Izv. prof. dr. sc. Radovan Antonić, dipl. ing.
Izv. prof. dr. sc. Tomislav Mrakovčić, dipl. ing.
Doc. dr. sc. Tomislav Senčić, dipl. ing.

Datum obrane: 6. rujna 2012.

Sastav Povjerenstva za obranu: Red. prof. dr. sc. Zmagoslav Prelec, dipl. ing.
Red. prof. dr. sc. Vladimir Medica, dipl. ing.
Izv. prof. dr. sc. Radovan Antonić, dipl. ing.
Izv. prof. dr. sc. Tomislav Mrakovčić, dipl. ing.
Doc. dr. sc. Tomislav Senčić, dipl. ing.

Datum promocije:

Oznaka: DD Tek. broj: UDK: 629.5.03-843.6:621.436.1.018:004.896:004.032.26(043)

PREDVIĐANJE PARAMETARA RADA BRODSKOG DIZELSKOG MOTORA
PRIMJENOM NEURONSKIH MREŽA

Ozren Bukovac

Sveučilište u Rijeci
Tehnički fakultet
Hrvatska

Ključne riječi: brodski dizelski motor; karakteristike dizelskog motora; umjetna inteligencija; neuronske mreže

SAŽETAK

U ovoj disertaciji provedene su numeričke simulacije za izračunavanje stacionarnih stanja rada motora. Rezultati numeričkih simulacija za uvjete rada brodskog dizelskog motora primijenjeni su za odabir vrste i strukture neuronske mreže koja je korištena u ovom radu, njeno učenje i validaciju. Razvijeni model neuronske mreže u stanju je dati tražene podatke karakteristika motora više od 3000 puta kraćem vremenu nego numeričke simulacije za zadanu stacionarnu radnu točku. U radu se istražuje efikasno predviđanje radnih parametara u svrhu optimalnog upravljanja. Isto tako pokazani su primjeri primjene opisane neuronske mreže za optimizaciju mogućih podešenja suvremenih brodskih "inteligentnih" dizelskih motora, s ciljem dovođenja traženog toplinskog toka ispušnih plinova u radne uvjete za potrebe utilizacije otpadne topline, uz minimalnu specifičnu potrošnju goriva na motoru, te za optimizaciju maksimalne temperature procesa motora u svrhu smanjenja emisija NO_x -a.

Rad nije objavljen.

Mentor: Red. prof. dr. sc. Vladimir Medica, dipl. ing.

Komentor: Izv. prof. dr. sc. Radovan Antičić, dipl. ing.

Povjerenstvo za ocjenu: Red. prof. dr. sc. Zmagoslav Prelec, dipl. ing.
Red. prof. dr. sc. Vladimir Medica, dipl. ing.
Izv. prof. dr. sc. Radovan Antičić, dipl. ing.
Izv. prof. dr. sc. Tomislav Mrakovčić, dipl. ing.
Doc. dr. sc. Tomislav Senčić, dipl. ing.

Povjerenstvo za obranu: Red. prof. dr. sc. Zmagoslav Prelec, dipl. ing.
Red. prof. dr. sc. Vladimir Medica, dipl. ing.
Izv. prof. dr. sc. Radovan Antičić, dipl. ing.
Izv. prof. dr. sc. Tomislav Mrakovčić, dipl. ing.
Doc. dr. sc. Tomislav Senčić, dipl. ing.

Datum obrane: 06. 09. 2012

Datum promocije:

Rad je pohranjen na Tehničkom fakultetu Sveučilišta u Rijeci.

(125 stranica, 83 slika, 8 tablica, 86 bibliografskih podataka, hrvatski jezik)

UDK: 629.5.03-843.6:621.436.1.018:004.896:004.032.26(043)

prodski dizelski motor
karakteristike dizelskog motora
umjetna inteligencija
neuronske mreže

Predviđanje parametara
rada brodskog dizelskog
motora primjenom
neuronskih mreža

I Bukovac O.

II Sveučilište u Rijeci
Tehnički fakultet
Hrvatska

D/

I.

Code: DD

No: UDC: 629.5.03-843.6:621.436.1.018:004.896:004.032.26(043)

PREDICTION OF MARINE DIESEL ENGINE'S OPERATING PARAMETERS
USING NEURAL NETWORKS

Ozren Bukovac

University of Rijeka
Faculty of Engineering
Croatia

Keywords: marine diesel engine; characteristics of a diesel engine; artificial intelligence; neural networks

ABSTRACT

This dissertation carried out numerical simulations to calculate the stationary operation states. The results of numerical simulations for heavy duty marine diesel engines were applied to select the type and structure of the neural network that is used in this paper, also for its learning and validation. Developed neural network model is able to provide the required engine data characteristics more than 3000 times faster than the numerical simulations for a given stationary operating point. This paper explores efficient prediction of operating parameters for optimal control. The dissertation presents examples of the neural networks application to optimize the potential of modern marine diesel engines, with the aim of achieving the required exhaust gases heat flow for waste heat utilization in the working conditions. As well, minimization of the engine specific fuel consumption, and optimization of the maximum process temperature to reduce emissions of NO_x's.

This thesis has not been published.

Advisors:

Full Professor D. Sc. Zmagoslav Prelec, dipl. ing.
Full Professor D. Sc. Vladimir Medica, dipl. ing.
Associate Professor D. Sc. Radovan AntoniĆ, dipl. ing.
Associate Professor D. Sc. Tomislav Mrakovćić, dipl. ing.
Assistant Professor D. Sc. Tomislav Senćić, dipl. ing.

Reviewers:

Full Professor D. Sc. Zmagoslav Prelec, dipl. ing.
Full Professor D. Sc. Vladimir Medica, dipl. ing.
Associate Professor D. Sc. Radovan AntoniĆ, dipl. ing.
Associate Professor D. Sc. Tomislav Mrakovćić, dipl. ing.
Assistant Professor D. Sc. Tomislav Senćić, dipl. ing.

Presentation: 06. 09. 2012

Degree conferred:

This thesis is deposited in the Library of the Faculty of Engineering, University of Rijeka.

(125 pages, 83 figures, 8 tables, 86 references, croatian language)

UDK: 629.5.03-843.6:621.436.1.018:004.896:004.032.26(043)

D/
I.
Prediction of Marine
Diesel Engine's Operating
Parameters Using
Artificial intelligence
Neural networks

I
Bukovac O.

II
University of Rijeka
Faculty of Engineering
Croatia