Računalna simulacija hlađenja baterijskog modula električnog zrakoplova

Lišnić, Matea

Master's thesis / Diplomski rad

2020

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:235:937742

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-05-14**

Repository / Repozitorij:

Repository of Faculty of Mechanical Engineering and Naval Architecture University of Zagreb

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Matea Lišnić

Zagreb, 2020.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Mentor: Student:

Doc. dr. sc. Severino Krizmanić, dipl. ing. Matea Lišnić

Zagreb, 2020.

Zahvaljujem se mentoru doc.dr.sc. Severinu Krizmaniću na stručnom vodstvu i pruženoj pomoći pri izradi ovog diplomskog rada. Također se želim zahvaliti kolegicama i kolegama iz Rimac Automobila na podijeljenim savjetima i prenesenom iskustvu. Na kraju se želim zahvaliti obitelji i prijateljima na podršci tijekom cijelog studija.

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

Matea Lišnić

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE
Središnje povjerenstvo za završne i diplomske ispite
Povjerenstvo za završne i diplomske ispite studija zrakoplovstva

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje	
Datum	Prilog
Klasa:	
Ur.broj:	

DIPLOMSKI ZADATAK

Studentica: **Matea Lišnić** Mat. br.: 0035195919

Naslov rada na hrvatskom jeziku: **Računalna simulacija hlađenja baterijskog modula električnog zrakoplova**

Naslov rada na engleskom jeziku: **Numerical simulation of electric airplane battery module cooling**

Opis zadatka:

Optimalne izvedbe sustava hlađenja motora kod malih zrakoplova s klasičnim motorima s unutarnjim izgaranjem su već dobro poznate, dok su elektromotorni pogoni zrakoplova relativno nova pojava u zrakoplovstvu, pa su tako i optimalne izvedbe njihovih podsustava predmet intenzivnog razvoja. U usporedbi s klasičnim motorima s unutarnjim izgaranjem, elektromotorni pogoni posjeduju vrlo visoki stupanj korisnosti, međutim zbog velike specifične snage i kompaktne izvedbe podsustava i u ovome se slučaju pojavljuje potreba za intenzivnim odvođenjem topline.

U sklopu razvoja malog zrakoplova s električnim pogonom, u ovom je radu potrebno provesti računalnu simulaciju hlađenja njegova baterijskog modula, koristeći metode računalne dinamike fluida.

U sklopu rada potrebno je:
- opisati objekt simulacije zadan postojećom tehničkom dokumentacijom i skicama idejnih rješenja, dijelove sustava hlađenja i njihove karakteristike;
- izraditi geometrijske i proračunske modele objekta simulacije, te prema potrebi uvesti pojednostavljenja;
- obaviti sve postupke računalnog proračuna: prostorna diskretizacija geometrijskih modela, odabir i podešavanje numeričkog postupka, post-procesiranje rješenja.

Rad treba sadržavati:
- uvod;
- opis problema i metoda primijenjenih za njihovo rješavanje;
- odgovarajuće prikaze dobivenih rezultata i osvrt na rezultate;
- zaključke.

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

Zadatak zadan:	Rok predaje rada:	Predviđeni datumi obrane:
14. studenoga 2019.	16. siječnja 2020.	20. – 24.1.2020.

Zadatak zadao:
Doc. dr. sc. Severino Krizmanić

Predsjednik Povjerenstva:
Prof. dr. sc. Milan Vrdoljak

SADRŽAJ

SADRŽAJ I
POPIS SLIKA II
POPIS TABLICA IV
POPIS OZNAKA V
SAŽETAK VII
SUMMARY VIII
1. UVOD 1
2. UPRAVLJANJE TOPLINOM ZRAKOPLOVNIH BATERIJSKIH PAKETA 2
2.1 Utjecaj temperature na Li-ionske baterije 2
2.2 Hlađenje baterija 3
2.2.1 Hlađenje tekućinama 4
2.2.2 Hlađenje plinovima 4
2.2.3 Hlađenje promjenom agregatnog stanja 8
2.3 Karakteristike prijenosa topline pri hlađenju zrakom 9
3. MATEMATIČKI MODEL 11
3.1 Turbulentno strujanje 14
3.2 Modeli turbulencije 16
3.3 k-ω SST model turbulencije 18
3.4 Rubni uvjeti 20
4. NUMERIČKA SIMULACIJA HLAĐENJA BATERIJSKOG MODULA 22
4.1 Referentni zrakoplov [15] 22
4.2 Odabir baterijskih ćelija 24
4.3 Dimenzioniranje modula pogonskog baterijskog paketa 26
4.4 Mreža 31
4.5 Početni i rubni uvjeti 34
5. REZULTATI 35
5.1 Utjecaj promjene protoka zraka na hlađenje baterijskog modula 37
5.2 Utjecaj uvođenja neuniformnih razmaka između ćelija na hlađenje baterijskog modula 45
6. ZAKLJUČAK 52
LITERATURA 54

POPIS SLIKA

Slika 2.1 Izvedbe asimetričnih (a) – (e) i simetričnih (f) – (j) geometrija modula [6] 7
Slika 2.2 Konusni oblik ulaznog i izlaznog kanala [7] 8
Slika 2.3 Utjecaj generirane topline i temperature fluida na ulazu na Q_{ITD} [9] 10
Slika 4.1 Električni zrakoplov Extra 330LE [15] 22
Slika 4.2 Geometrija i dimenzije baterijske ćelije Samsung 21700-48G [16] 24
Slika 4.3 Serijski i paralelni spoj ćelija u modulu 26
Slika 4.4 Kućište modula (1) 27
Slika 4.5 Kućište modula (2) 28
Slika 4.6 Dio kućišta modula s baterijama 28
Slika 4.7 Pojednostavljena geometrija 29
Slika 4.8 Pojednostavljena geometrija s neuniformnim razmacima između ćelija 30
Slika 4.9 Mreža konačnih volumena 32
Slika 4.10 Detaljniji prikaz mreže na rubovima zrak/ćelija 32
Slika 4.11 Prikaz mreže u poprečnom presjeku 33
Slika 5.1 Konvergencija prosječne temperature ćelija u modulu s uniformnim razmakom između ćelija i brzinom zraka na ulazima od 20 m/s 36
Slika 5.2 Konvergencija prosječne temperature ćelija u modulu s uniformnim razmakom između ćelija i brzinom zraka na ulazima od 40 m/s 36
Slika 5.3 Konvergencija prosječne temperature ćelija u modulu s neuniformnim razmakom između ćelija 37
Slika 5.4 Temperaturno polje [K]ćelija pri brzini strujanja na ulazu od 20 m/s i uniformnim razmakom između ćelija 38
Slika 5.5 Temperaturno polje [K]ćelija pri brzini strujanja na ulazu od 40 m/s i uniformnim razmakom između ćelija 38
Slika 5.6 Temperaturno polje [K] ćelija pri brzini strujanja na ulazu od 20 m/s i uniformnim razmakom između ćelija –strana ćelija bliže ulazima (gornja slika) i strana ćelija bliže izlazima (donja slika) 39
Slika 5.7 Temperaturno polje [K] ćelija pri brzini strujanja na ulazu od 40 m/s i uniformnim razmakom između ćelija –strana ćelija bliže ulazima (gornja slika) i strana ćelija bliže izlazima (donja slika) 39
Slika 5.8 Polje tlaka [Pa] ćelija pri brzini strujanja na ulazu od 20 m/s i uniformnim razmakom između ćelija 42
Slika 5.9 Polje tlaka [Pa] ćelija pri brzini strujanja na ulazu od 40 m/s i uniformnim razmakom između ćelija 42
Slika 5.10 Distribucija brzine [m/s] zraka u modulu s uniformnim razmakom između ćelija i pri brzini strujanja na ulazu od 20 m/s 43
Slika 5.11 Distribucija brzine [m/s] zraka u modulu s uniformnim razmakom između ćelija i pri brzini strujanja na ulazu od 40 m/s 43
Slika 5.12 Temperaturno polje [K] zraka oko ćelija pri brzini strujanja na ulazu od 20 m/s i uniformnim razmakom između ćelija 44

Slika 5.13 Temperaturno polje [K] zraka oko ćelija pri brzini strujanja na ulazu od 40 m/s i uniformnim razmakom između ćelija....44
Slika 5.14 Temperaturno polje [K]ćelija pri brzini strujanja na ulazu od 20 m/s i uniformnim razmakom između ćelija....46
Slika 5.15 Temperaturno polje [K]ćelija pri brzini strujanja na ulazu od 20 m/s i neuniformnim razmakom između ćelija....46
Slika 5.16 Temperaturno polje [K] ćelija pri brzini strujanja na ulazu od 20 m/s i uniformnim razmakom između ćelija –strana ćelija bliže ulazima (gornja slika) i strana ćelija bliže izlazima (donja slika)....47
Slika 5.17 Temperaturno polje [K] ćelija pri brzini strujanja na ulazu od 20 m/s i neuniformnim razmakom između ćelija –strana ćelija bliže ulazima (gornja slika) i strana ćelija bliže izlazima (donja slika)....47
Slika 5.18 Polje tlaka [Pa] ćelija pri brzini strujanja na ulazu od 20 m/s i uniformnim razmakom između ćelija....49
Slika 5.19 Polje tlaka [Pa] ćelija pri brzini strujanja na ulazu od 20 m/s i neuniformnim razmakom između ćelija....49
Slika 5.20 Distribucija brzine [m/s] zraka u modulu s uniformnim razmakom između ćelija i pri brzini strujanja na ulazu od 20 m/s....50
Slika 5.21 Distribucija brzine [m/s] zraka u modulu s neuniformnim razmakom između ćelija i pri brzini strujanja na ulazu od 20 m/s....50
Slika 5.22 Temperaturno polje [K] zraka oko ćelija pri brzini strujanja na ulazu od 20 m/s i neuniformnim razmakom između ćelija....51

POPIS TABLICA

Tablica 2.1 Karakteristike zraka....9
Tablica 4.1 Karakteristike zrakoplova Extra 330LE Electric Aircraft....23
Tablica 4.2 Karakteristike elektromotora SP260D....23
Tablica 4.3 Karakteristike pogonskog baterijskog paketa....23
Tablica 4.4 Termodinamičke značajke baterijske ćelije Samsung 21700-48G....25
Tablica 4.5 Karakteristike baterijske ćelije....25
Tablica 4.6 Karakteristike baterijskog modula....27
Tablica 4.7 Raspored neunifomnih razmaka između ćelija....30
Tablica 4.8 Mreža konačnih volumena....31
Tablica 4.9 Maksimalna neortogonalnost i maksimalno skošenje konačnih volumena....33
Tablica 4.10 Početni uvjeti strujanja....34
Tablica 5.1 Temperaturno stanje ćelija pri hlađenju s uniformnim razmakom između ćelija..37
Tablica 5.2 Stanje zraka pri hlađenju s uniformnim razmakom između ćelija....40
Tablica 5.3 Potrebna snaga za svadavanje pada tlaka u modulu....41
Tablica 5.4 Temperaturno stanje ćelija pri hlađenju s uniformnim i neuniformnim razmakom između ćelija....45
Tablica 5.5 Stanje zraka pri hlađenju s uniformnim razmakom između ćelija....48

POPIS OZNAKA

Oznaka	**Jedinica**	**Opis**
c	[J/(kg K)]	specifični toplinski kapacitet
C_{nom}	[A h]	nominalni kapacitet
e	[J/kg]	zbroj specifične unutarnje i kinetičke energije
$E_{ćelija}$	[kW h]	električna energija ćelije
E_{modul}	[kW h]	električna energija modula
E_{paket}	[kW h]	električna energija paketa
f		skalarno polje
$\bar{f}$		statistički osrednjeni dio skalarnog polja f
f'		pulzirajući dio skalarnog polja f
f_i	[N/kg]	komponente vektora specifične masene sile
I_{max}	[A]	maksimalna jačina struja
$\bar{k}$	[J/kg]	kinetička energija turbulencije
l_t	[m]	put miješanja čestica u turbulentnom strujanju
$\dot{m}$	[kg/s]	maseni protok
p	[N/m^2]	tlak
$\bar{p}$	[N/m^2]	statistički osrednjeni dio polja tlaka p
p'	[N/m^2]	pulzirajući dio polja tlaka p
$\overline{p_e}$	[N/m^2]	efektivni tlak
Δp	[N/m^2]	pad tlaka
P	[W]	snaga
Pr	[-]	Prandtlov broj
q_i	[W/m^2]	komponente vektora površinske gustoće toplinskog toka
Q	[W]	toplina
Q_{ITD}	[W/K]	toplina koju generira ćelija normirana s razlikom temperature ćelije i temperature rashladne tvari na ulazu
Re	[-]	Reynoldsov broj
S_T		izvorski član temperaturne jednadžbe
t	[s]	vrijeme
T	[K]	temperatura
$\bar{T}$	[K]	statistički osrednjeni dio polja temperature T
T'	[K]	pulzirajući dio polja temperature T
T_0	[s]	period osrednjavanja
u	[J/kg]	specifična unutarnja energija
U_{nom}	[V]	nominalni napon baterijske ćelije
U_{max}	[V]	maksimalni napon baterijske ćelije
U_{modul}	[V]	napon baterijskog modula
U_{paket}	[V]	napon baterijskog paketa

v_i	[m/s]	komponente vektora brzine
$\bar{v}_i$	[m/s]	statistički osrednjeni dio polja brzine v
v_i'	[m/s]	pulzirajući dio polja brzine v
v_t	[m/s]	brzina turbulentnih pulsacija
V	[m/s]	brzina
x_i	[m]	pravokutne koordinate
δ_{ij}	[-]	Kroneckerov simbol
ε	[W/kg]	disipacija kinetičke energije turbulencije
λ	[W/(m K)]	toplinska vodljivost
μ	[Pa s]	dinamička viskoznost
μ_e	[Pa s]	efektivna dinamička viskoznost
μ_t	[Pa s]	turbulentna dinamička viskoznost
ν	[m^2/s]	kinematička viskoznost
ν_T	[m^2/s]	turbulentna kinematička viskoznost
ρ	[kg/m^3]	gustoća
σ_{ji}	[N/m^2]	komponenta simetričnog tenzora naprezanja
σ_k , σ_T , σ_ω	[-]	Schmidtovi brojevi
τ_{ij}	[N/m^2]	komponente tenzora viskoznih naprezanja
ω	[s^{-1}]	specifična disipacija turbulentne kinetičke energije

SAŽETAK

Tema ovog diplomskog rada jest upravljanje toplinom pogonskih baterijskih paketa zrakoplova. U prvom dijelu dan je uvid u načine, prednosti i nedostatke pojedinih vrsta hlađenja i matematički model koji čini podlogu numeričkim simulacijama hlađenja baterijskog paketa. U drugom se dijelu detaljnije razmatra hlađenje zrakom pogonskog baterijskog paketa zrakoplova. Karakteristike baterijskog paketa pri tome određene su prema referentnom potpuno električnom zrakoplovu Extra 330LE i Samsungovim Li-ionskim cilindričnim ćelijama. Na temelju ranije razmatranih uvjeta i karakteristika hlađenja zrakom sastavljena je geometrija modula te je za nju provedena računalna simulacija hlađenja i analiza dobivenih rezultata.

Ključne riječi: hlađenje, baterije, električni zrakoplovi, numeričke simulacije

SUMMARY

Topic of this master thesis is the aircraft propulsion battery pack thermal management system. In the first part a short description of different kinds of battery cooling systems along with it's advantages and disadvantages is given. Along with a short overwiev of battery cooling managment system, the first part of this paper also deals with mathematical model which is base for CFD simulation. The CFD simulation is discussed trougout the rest of the paper.

In the second part of the master thesis highlight is on the air cooling of the aircraft propulsion battery pack. The properties of the aircraft battery module were estimated according to the one found in fully electric aircraft Extra 330LE and Samsung Li-ion cylindrical battery cells. Based on those properties, the reference module is designed and CFD simulation is conducted. In the end the results are given and discussed.

Key words: battery thermal management system, cooling, electric aircraft, CFD

1. UVOD

Podizanjem svijestiti o zaštiti okoliša i klimatskim promjenama, zadnjih se godina sve više pažnje pridaje razvoju električnih vozila od čega posebnu skupinu čine zrakoplovi. Električni zrakoplovi u usporedbi sa zrakoplovima pogonjenim motorima s unutarnjim izgaranjem daju par značajnih prednosti kao što su na primjer energetska učinkovitost, značajno smanjen utjecaj na okoliš, smanjena buka, manja ovisnost o fosilnim gorivima, itd. Unatoč mnogim prednostima koje nam nude potpuno električna vozila, njihovoj široj primjeni najveću prepreku predstavljaju baterijski paketi. Glavne značajke baterijskih paketa pri tome su cijena, domet, pouzdanost, sigurnost, kapacitet, životni vijek te vrijeme punjenja. Velik dio ovih značajki ovisi upravo o upravljanju toplinom koju generiraju baterije pri radu te je zbog toga važno osigurati adekvatno hlađenje baterije. Za napajanje električnih zrakoplova najčešće se koriste Li-ionske baterije zbog svoje relativno visoke gustoće energije, visoke učinkovitosti, dužeg životnog ciklusa i trenutačno zadovoljavajuće razine ekološke prihvatljivosti. Kako bi se osigurao optimalni rad i što duži radni vijek litij-ionskih baterija, potrebno je osigurati određenu temperaturu baterije te minimizirati temperaturnu razliku kako unutar baterijskog paketa tako i unutar same ćelije. Hlađenje baterija može biti izvedeno na razne načine, a trenutno najzastupljenije je hlađenje tekućinama. Iako je hlađenje tekućinama trenutačno najviše primjenjivano zbog svoje pouzdanosti i visoke učinkovitosti koja proizlazi iz visokog toplinskog kapaciteta tekućina s obzirom na plinove, hlađenje plinovima predstavlja zanimljivu i potencijalnu alternativu zbog manje mase ovakvih sustava što je iznimno bitno u zrakoplovstvu te jednostavnosti održavanja ovakvih sustava u usporedbi sa sustavima hlađenim tekućinama. Kako bi se osiguralo adekvatno hlađenje baterijskih paketa zrakom, potrebno je optimizirati protok zraka koji zbog niskog toplinskog kapaciteta treba biti značajno veći od onog pri hlađenju tekućinama. Pri tome velik izazov predstavlja pad tlaka koji raste s kvadratom protoka te tako značajno povećava energijske gubitke unutar baterijskog modula.

2. UPRAVLJANJE TOPLINOM ZRAKOPLOVNIH BATERIJSKIH PAKETA

Baterijski paketi u zrakoplovima koriste se za razne funkcije poput izvora energije prizemljenog zrakoplova, hitnih izvora energije, za poboljšanje stabilnosti sabirnice istosmjerne struje i sl. Najčešće korištene baterije u zrakoplovima ovisno o namjeni jesu nikal-kadmijeva (NiCd) , nikal-metalna (Ni-MH), litij-ionska, litij-polimerna te olovna. Odgovarajuća vrsta baterije za određenu funkciju određuje se na temelju nekoliko karakteristika kao što su težina, cijena, volumen, životni vijek, brzina punjenja i pražnjenja, mogućnost održavanja. [1] Osim što služe kao dodatni izvori energije, sve većim razvojem električnih zrakoplova zadnjih godina, baterijski paketi postepeno dobivaju i ulogu glavnog tj. pogonskog izvora energije. Za tu funkciju najčešće se koriste Li-ionske baterije koje karakterizira visoka energetska gustoća u odnosu na ostale vrste baterija i relativno visok životni vijek pri kontroliranim operativnim temperaturama.

2.1 Utjecaj temperature na Li-ionske baterije

Glavni faktor koji utječe na performanse i životni vijek baterijskih paketa jest temperatura. Li-ionske baterije rade optimalno na temperaturama između 25 °C i 35 °C, no mogu raditi i pri većim temperaturnim rasponima. Ovisno o vrsti Li-ionske baterije ovaj raspon može se povećati ili smanjiti. U slučaju temperatura ispod 0 °C ili iznad 50 °C značajno se smanjuje kako razina pohranjene energije tako i općenito životni vijek baterije. Visoke temperature povećavaju rast interakcijskog sloja između solida i elektrolita te se tako povećava unutarnji otpor baterije što za posljedicu daje smanjenje energije koja se predaje trošilu. U slučaju ekstremno visokih temperatura može doći do taljenja razdjelnika što uzrokuje kratki spoj unutar baterije te time uzrokuje velike termalne oscilacije. Baterije mogu izdržati visoke temperature kratkotrajno, no ako je napunjena baterija duže vrijeme na temperaturama većim od 60 °C postoji rizik od rupture, eksplozije ili zapaljivanja. Pri operativnim temperaturama baterija nižim od 0 °C dolazi do smanjenja kapaciteta baterija te stvaranja litijske obloge prilikom punjenja.

Temperatura baterije i njezina uniformnost imaju snažan utjecaj na dostupnu snagu punjenja i pražnjenja, balansiranje ćelija i razinu punjenja koja će se prihvatiti prilikom primjerice, regenerativnog kočenja kod električnih vozila. Velike razlike u temperaturi u baterijskom paketu mogu dovesti do različitog punjenja i pražnjenja ćelija i time do električno neuravnoteženih baterijskih ćelija što uzrokuje smanjenju performansi baterijskog paketa. Zbog toga varijacije temperature unutar ćelije trebaju biti održavane između 5 °C i 10 °C dok bi varijacije temperature unutar baterijskog paketa trebale biti unutar 3 °C do 5 °C. Temperaturna razlika od 5 °C može dovesti do smanjenja sposobnosti proizvodnje snage od 10 % i inkrementa kinematike termičkog starenja do 25 %. Gledajući dugoročno ovakve temperaturne razlike također utječu i na stupanj samopražnjenja baterije te mogu utjecati i na smanjenje efektivne operativne napunjenosti. Termičko i cikličko starenje uzrok su smanjenju kapaciteta i povećanju unutrašnjeg otpora ćelije te tako određuju životni vijek baterije. Razina smanjenja životnog vijeka ćelije ovisi također i o stupnju napunjenosti, gdje potpuno napunjena baterija degradira brže nego baterija koja nije potpuno napunjena. [2]

2.2 Hlađenje baterija

Zagrijavanje baterijske ćelije rezultat je kemijskih reakcija koje se događaju tijekom punjenja i pražnjenja te unutarnjeg otpora ćelije. Kako baterije rade samo u određenom temperaturnom intervalu, bitno je osigurati adekvatno hlađenje ćelija. U slučajevima visokih nadmorskih visina, zbog vrlo niskih temperatura zraka, ili u područjima s ekstremnim zimskim uvjetima, moguće je da će ćelije umjesto hlađenja trebati zagrijavati.

Količina proizvedene topline unutar ćelije ovisi o vrsti baterije, pri čemu je bitan materijal reakcijskih slojeva, anode i katode, te tipu ćelije (pravokutne, cilindrične, prizmatične …) Osim generacije topline, o vrsti baterije i tipu ćelije ovisi također i toplinska provodnost koja može varirati i unutar pojedine ćelije ovisno o smjeru. Tako na primjer kod cilindričnih baterija zbog namotavanja reakcijskih slojeva toplinska provodnost u aksijalnom smjeru (unutar reakcijskog sloja) značajno je veća nego u radijalnom smjeru (poprečno na reakcijski sloj). Ova razlika može varirati i par desetaka puta. Životni vijek baterije osim o operativnoj temperaturi značajno ovisi i o razlici temperature unutar svake ćelije. Kako bi se osigurao što duži životni vijek potrebno je imati što uniformniji temperaturni profil unutar cijele ćelije.

Hlađenje baterijskih paketa odnosno modula obavlja se pomoću fluida koji strujanjem preko ćelija služi kao rashladna tvar. Ovisno o izboru fluida, hlađenje možemo podijeliti na hlađenje tekućinama, plinovima te hlađenje pomoću promijene faze (PCC – phase change composite thermal materials).

2.2.1 Hlađenje tekućinama

Hlađenje tekućinama može biti izvedeno na razne načine pri čemu ćelije mogu biti u direktnom ili indirektnom kontaktu s rashladnom tekućinom. Uzimajući to u obzir ako su ćelije u direktnom kontaktu s rashladnom tekućinom, za rashladnu tekućinu treba biti izabran dielektrik poput mineralnih ulja ili ulja na bazi silicija kako ne bi došlo do kratkog spoja. U suprotnom za rashladnu tekućinu može se uzeti bilo koja tekućina poput vode ili vode-glikola.

Prednosti direktnog hlađenja su kompaktnost, veća temperaturna uniformnost između ćelija te veći stupanj hlađenja u odnosu na hlađenje zrakom. Nedostaci ovakvog hlađenja su mogućnost hlađenja samo ako imamo dostupan izvor energije te nemogućnost integriranja sustava za grijanje koji je potreban na temperaturama ispod 0 °C. Prednosti indirektnog hlađenja tekućinama su veća prosječna energetska učinkovitost, veći stupanj hlađenja u usporedbi s hlađenjem zrakom, lakše održavanje i mogućnost integriranja sustava za grijanje. Nedostaci ovakvog sustava su povećanje mase i potrebnog volumena, veća cijena zbog kompleksnosti sustava te veća inercija zbog velike termalne mase. [2]

Hlađenje tekućinama efektivan je način odvođenja veće količine energije pomoću relativno niskih protoka. Dodatni tehnički problemi koji se javljaju kod ovakvog načina hlađenja jesu brtvljenje kako bi se spriječilo curenje rashladne tekućine i korozija. Također ovakav način hlađenja pridonosi većim operativnim troškovima.

2.2.2 Hlađenje plinovima

Hlađenje plinovima može se nadalje podijeliti na prirodnu i prisilnu konvekciju pri čemu prisilna konvekcija pokazuje znatno bolje rezultate. Ovaj način hlađenja karakterizira jednostavniji sustav, manja masa i jednostavnije održavanje. Problem kod hlađenja plinovima jest znatno manji toplinski kapacitet plinova u odnosu na tekućine što za rezultat daje

potreban znatno veći volumni protok kako bi se zadovoljile potrebe hlađenja. Drugi problemi koji se javljaju kod sustava hlađenja plinovima su neuniformno hlađenje unutar baterijskog modula koje značajno ovisi o geometriji modula, smještanje sustava u zrakoplov zbog znatno većeg volumena ovih sustava u odnosu na one hlađene tekućinama i veća generacija buke zbog kretanja veće količine zraka kroz sustav. [3]

Na performanse hlađenja plinovima značajno utječe stanje zraka na ulazu u paket odnosno modul, a pri tome dvije najvažnije veličine jesu temperatura i protok zraka. Porastom temperature zraka na ulazu raste maksimalna temperatura baterijskog paketa, ali se smanjuje maksimalna temperaturna razlika unutar paketa [4]. Maksimalna temperatura i maksimalna temperaturna razlika baterijskog paketa smanjuju se porastom protoka zraka [5]. Porastom protoka zraka, raste protok kroz kanale između ćelija i tako doprinosi povećanju koeficijenta konvektivnog prijenosa topline.

Utjecaj konstrukcije modula na hlađenje zrakom

Osim ulaznog stanja plina na distribuciju brzine, a time i prijenosa topline između ćelija i zraka, značajno utječe i struktura modula baterijskog sustava za upravljanje toplinom. Uz samo stanje zraka, postoji nekoliko različitih karakteristika konstrukcije na koje je pri tome potrebno obratiti pažnju, a to su:

- oblik ćelije
- broj ćelija u modulu
- geometrija modula
- razmak između ćelija
- položaj, veličina i oblik ulaza i izlaza

Prema svojoj geometriji, baterijske ćelije podijeljene su na osnosimetrične i one koje nisu osnosimetrične. Pri tome osnosimetrične ćelije pokazuje bolje performanse pri hlađenju.

Veći broj ćelija u modulu značajno povećava neuniformnu distribuciju temperature unutar modula. Ova pojava rezultat je neravnomjernog protoka zraka između ćelija.

Pri konstruiranju geometrije modula dobro je staviti ulaz odnosno ulaze s donje strane modula, a izlaz ili izlaze s gornje strane. Ovakva geometrija utječe povoljno jer je gibanje

zagrijanog zraka pri slobodnoj konvekciji usmjereno prema gore, što u ovom slučaju komplementira prisilnoj konvekciji. Slika 2.1 prikazuje razne moguće načine izvedbe asimetričnih (a) – (e) i simetričnih (f) – (j) geometrija modula s različitim brojem i položajima ulaza i izlaza [6]. Druga stvar koja značajno diktira kvalitetu hlađenja jest razmak između ćelija. Smanjenjem razmaka između ćelija uz fiksni protok smanjuje se temperatura ćelija. Kako geometrija modula značajno utječe na unifomnost hlađenja ćelija unutar modula, moguće je dodatno poboljšati hlađenje uvođenjem neuniformnih razmaka između ćelija čime se osim na postizanje uniformnije temperature ćelija unutar modula povoljno utječe i na energijske gubitke unutar modula. Na mjestima gdje je protok zagušen potrebno je povećati razmak između ćelija kako bi se smanjio pad tlak na tim mjestima i time olakšalo strujanje.

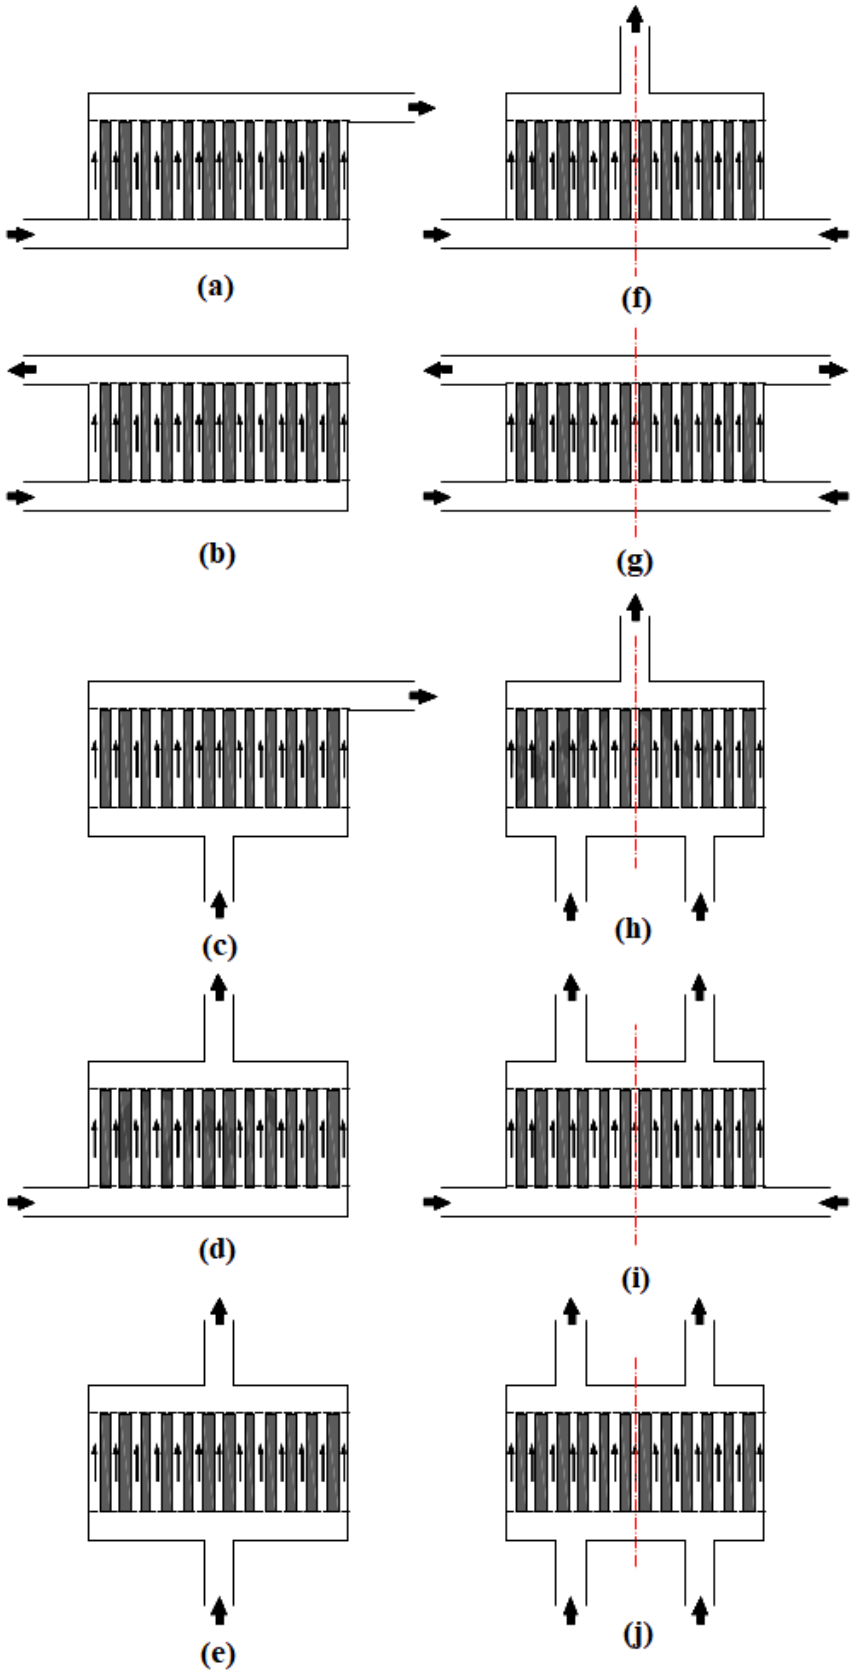

Slika 2.1 Izvedbe asimetričnih (a) – (e) i simetričnih (f) – (j) geometrija modula [6]

Performanse hlađenja moguće je dodatno poboljšati uvođenjem konusnog oblika ulaznog i izlaznog kanala, pri čemu ulazni kanal treba biti konvergentan, a izlazni divergentan. Uvođenjem konvergentnog kanala na strani usisa i divergentnog kanala na izlazu, maksimalna temperaturna razlika unutar baterijskog paketa može biti smanjena za 30% ili više nakon optimizacije [7]. Primjer geometrije s kovergentno-divergentnim kanalima dan je na slici 2.2.

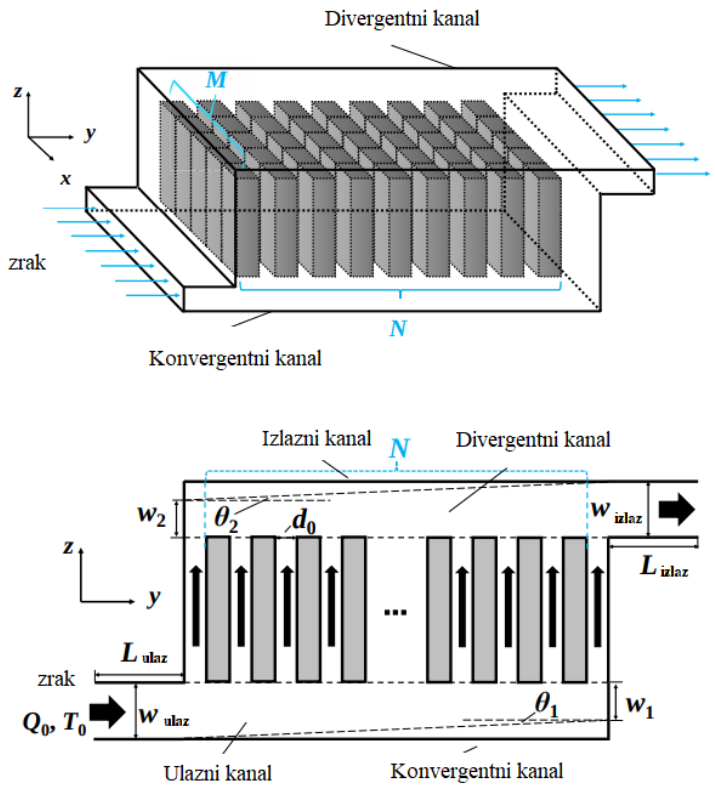

Slika 2.2 Konusni oblik ulaznog i izlaznog kanala [7]

2.2.3 Hlađenje promjenom agregatnog stanja

Hlađenje promjenom agregatnog stanja odnosi se na PCC materijale. Ovi materijali kombinacija su ugljika i određenog materijala koji mijenja agregatno stanje, a u slučaju hlađenja u direktnom su kontaktu s baterijskim ćelijama. Ugljik pri tome osigurava provođenje topline proizvedene zagrijavanjem ćelija izbjegavajući na taj način pojavu temperaturnih skokova. Jednom kad temperatura dosegne temperaturu taljenja, dodatna energija proizvedena zagrijavanjem ćelija troši se na promjenu agregatnog stanja rashladnog

materijala umjesto podizanja temperature sustava. Posebnom kombinacijom ovih materijala osigurava se da ne dolazi to promjene oblika i curenja ovakvih kompozitnih struktura. [8]

2.3 Karakteristike prijenosa topline pri hlađenju zrakom

Na prijenos topline utječe nekoliko značajnih faktora poput geometrije, protoka, uvjeta pod kojima je ostvaren protok i termodinamičkih značajki fluida, u ovom slučaju zraka. Karakteristike zraka uzete su za nadmorsku visinu i temperaturu od 20°C, a dane su u tablici 2.1 .

Tablica 2.1 Karakteristike zraka

Gustoća [kg/m^3]	1.16
Specifični toplinski kapacitet [kJ/kgK]	1.006
Toplinska provodnost [W/mK]	0.028
Dinamička viskoznost [kg/ms]	1.81×10^{-5}

Ukupna toplina prenesena s ćelije na zrak produkt je koeficijenta prijenosa topline, ukupne površine preko koje se toplina izmjenjuje i razlike srednjih temperatura ćelija i zraka. Kako je srednja temperatura zraka T_{zrak} definirana temperaturom zraka na ulazu T_{ulaz}, toplinom preuzetom s ćelije Q, masenim protokom zraka $\dot{m}$ i specifičnim toplinskim kapacitetom zraka C_p prema formuli:

$$T_{zrak} = T_{ulaz} + \frac{Q}{2 \cdot \dot{m} \cdot C_p} \qquad (2.1)$$

možemo zaključiti da su jedine dvije veličine kojima možemo utjecati na smanjenje srednje temperature zraka što manja temperatura na ulazu i što veći protok. Smanjenje srednje temperature zraka povećat će temperaturnu razliku između ćelija i zraka i time poboljšati prijenos topline. Nadalje kako bi se postiglo što uniformnije hlađenje ćelija unutar baterijskog modula važno je da razlika između ulazne i izlazne temperature bude što manja što stavlja dodatni zahtjev na povećanje protoka zraka.

Usporedba zahtjeva na početne uvjete za hlađenje zrakom i fluidom

Toplina koju generira ćelija normirana s razlikom temperature ćelije i temperature rashladne tvari na ulazu označava se s Q_{ITD}.

$$Q_{ITD} = \frac{Q}{T_{ćelije} - T_{ulaz}} \qquad (2.2)$$

Q_{ITD} za zrak iznosi oko 70 W/K za održavanje ćelije na prosječnoj temperaturi od 35 °C, dok je ista ta toplina za fluid približno 500 W/K. Sukladno tome za hlađenje 1.5 kW generirane topline zrakom potrebna je temperatura zraka na ulazu od 13 °C i volumni protok od približno 200 m^3/h. Za hlađenje iste količine generirane topline fluidom potrebna je temperatura na ulazu od 32 °C i volumni protok od 0.6 m^3/h. Slika 2.3 detaljnije prikazuje zahtjeve temperature na ulazu za različite iznose generirane topline i različite Q_{ITD}, koji su tipični za današnje baterijske module. [9]

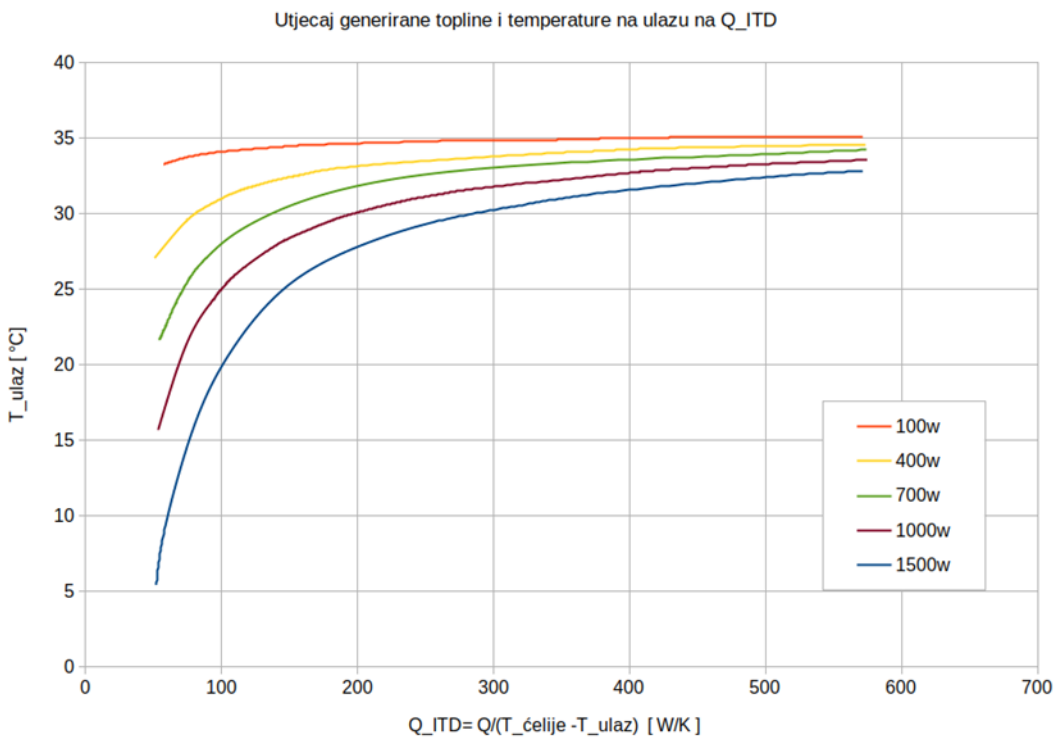

Slika 2.3 Utjecaj generirane topline i temperature fluida na ulazu na Q_{ITD} [9]

3. MATEMATIČKI MODEL

Matematički model nestlačivog, turbulentnog strujanja zraka unutar izmjenjivača topline baterijskog modula opisan je sustavom nelinearnih parcijalnih diferencijalnih jednadžbi. U ovom poglavlju biti će pobliže opisane jednadžbe potrebne za numeričku simulaciju baterijskog modula koji je daljnja tema ovog rada. Sve potrebne jednadžbe pri tome proizlaze iz tri osnovne jednadžbe dinamike fluida, a to su:

- Zakon očuvanja mase

$$\frac{\partial}{\partial x_j}\left(\rho v_j\right) = 0 \quad (3.1)$$

gdje je ρ gustoća fluida, v_j komponente vektora brzine strujanja fluida, a x_j pravokutne koordinate.

- Zakon količine gibanja

$$\frac{\partial}{\partial t}(\rho v_i) + \frac{\partial}{\partial x_j}\left(\rho v_j v_i\right) = \rho f_i + \frac{\partial \sigma_{ji}}{\partial x_j} \quad (3.2)$$

gdje su f_i komponente vektora specifične masene sile, σ_{ji} komponente simetričnog tenzora naprezanja i t vrijeme.

- Zakon očuvanja energije

$$\frac{\partial}{\partial t}(\rho e) + \frac{\partial}{\partial x_j}\left(\rho v_j e\right) = \rho f_i v_i + \frac{\partial}{\partial x_j}\left(\sigma_{ji} v_i\right) - \frac{\partial q_i}{\partial x_i} \quad (3.3)$$

gdje je $e = u + v^2/2$ odnosno zbroj specifične unutarnje i kinetičke energije čestice fluida , a q_i komponenta vektora površinske gustoće toplinskog toka.

Navedeni zakoni ne mogu jednoznačno opisati strujanje fluida jer se broj jednadžbi ne slaže s brojem nepoznanica. Zbog toga se uvode dopunske jednadžbe:

- Newtonov zakon viskoznosti

  Uz pretpostavku da u mirujućem fluidu vlada tlak p, a da su tangencijalna naprezanja jednaka nuli slijedi izraz za komponente tenzora naprezanja:

$$\sigma_{ij} = -p\delta_{ij} + \tau_{ij} \quad (3.4)$$

  gdje je δ_{ij} Kroneckerov simbol, a τ_{ij} komponente simetričnog tenzora viskoznih naprezanja. Tenzor viskoznih naprezanja za izotropni fluid uz zanemarivanje koeficijenta volumenske viskoznosti dan je izrazom:

$$\tau_{ij} = \mu\left(\frac{\partial v_i}{\partial x_j} + \frac{\partial v_j}{\partial x_i}\right) \quad (3.5)$$

  gdje je μ dinamička viskoznost fluida.

- Furierov zakon toplinske vodljivosti

$$q_i = -\lambda\frac{\partial T}{\partial x_i} \quad (3.6)$$

  gdje je λ toplinska vodljivost fluida.

Uvrštavanjem (3.4) – (3.6) u osnovne jednadžbe (3.1) - (3.3) dobivamo potpuni sustav Navier-Stokesovih jednadžbi.

$$\frac{\partial}{\partial x_j}(\rho v_j) = 0 \quad (3.7)$$

$$\frac{\partial}{\partial t}(\rho v_i) + \frac{\partial}{\partial x_j}(\rho v_j v_i) = \rho f_i - \frac{\partial p}{\partial x_i} + \frac{\partial \tau_{ij}}{\partial x_j} \quad (3.8)$$

$$\frac{\partial}{\partial t}(\rho e) + \frac{\partial}{\partial x_j}\left(\rho v_j e\right) = \rho f_i v_i - \frac{\partial}{\partial x_i}(p v_i) + \frac{\partial}{\partial x_j}\left(\tau_{ij} v_i\right) + \frac{\partial}{\partial x_i}(\lambda \frac{\partial T}{\partial x_i}) \quad (3.9)$$

Ovaj sustav uz odgovarajuće početne i rubne uvjete vrijedi za laminarno strujanje viskoznog newtonskog fluida.

U slučaju nestlačivog fluida konstantne gustoće, specifična unutarnja energija može se izraziti pomoću specifičnog toplinskog kapaciteta i temperature prema izrazu:

$$u = cT \quad (3.10)$$

gdje c predstavlja specifični toplinski kapacitet. Uvrstimo li izraz (3.10) u energijsku jednadžbu (3.9) te od nje oduzmemo jednadžbu mehaničke energije, koja se dobije kao umnožak jednadžbe količine gibanja (3.8) i vektora brzine, dobivamo izraz za temperaturnu jednadžbu.

$$\frac{\partial}{\partial t}(\rho T) + \frac{\partial}{\partial x_j}\left(\rho v_j T\right) = \frac{\partial}{\partial x_i}\left(\frac{\lambda}{c}\frac{\partial T}{\partial x_i}\right) + \frac{1}{c}\tau_{ij}\frac{\partial v_i}{\partial x_j} \quad (3.11)$$

Kako turbulentno strujanje karakterizira pojava pulzacija svih varijabli oko njihovih statistički srednjih vrijednosti, što ga čini stohastičkim i nemogućim za analitičko rješavanje potrebno je uvesti odgovarajući model turbulencije.

Granica između laminarnog i turbulentnog strujanja određuje se pomoću kritične vrijednosti Reynoldsovog broja prema izrazu

$$Re = \frac{\rho V L}{\mu} \quad (3.12)$$

gdje su V i L karakteristične vrijednosti brzine i duljine za promatrano strujanje.

[10],[11]

3.1 Turbulentno strujanje

Turbulentno strujanje fluida karakteriziraju slučajne promjene raznih veličina u vremenskoj i prostornim koordinatama. Pri tome moguće je jasno razlučiti statistički osrednjene vrijednosti tih veličina, a s obzirom na nestacionarnost turbulentnog strujanja, prikladno je koristiti vremensko osrednjavanje (Reynoldsovo vremensko osrednjavanje) kojime se turbulentno strujanje dijeli na statistički osrednjeni i pulzirajući dio. Bilo koje skalarno polje f kvazistacionarnog turbulentnog strujanja u nekoj točki može se prikazati zbrojem statistički osrednjenog dijela $\bar{f}$ koje nije funkcija vremena i pulzirajućeg dijela f' koji je uvijek funkcija vremena.

$$f = \bar{f} + f' \quad (3.13)$$

Pri tome statistički osrednjeni dio dobije se vremenskim osrednjavanjem prema izrazu

$$\bar{f}(x_i) = \frac{1}{T_0} \int_{-\frac{T_0}{2}}^{\frac{T_0}{2}} f(x_i, t)dt \quad (3.14)$$

gdje je T_0 period osrednjavanja izabran tako da u kvazistacionarnom strujanju bude zadovoljen uvjet da $\bar{f}$ nije funkcija vremena. Na sličan način vrši se i vremensko osrednjavanje strujanja koje nije kvazistacionarno. Razlika se javlja samo u periodu osrednjavanja koji u tom slučaju mora biti dovoljno velik u usporedbi s odgovarajućim karakterističnim vremenom turbulentnog strujanja, a u isto vrijeme dovoljno mali kako ne bi zahvatio ostale nestacionarne pojave.

U jednadžbama (3.13) – (3.15) prikazane su komponente brzine, tlaka i temperature u obliku zbroja vremenski osrednjenog i pulzirajućeg dijela.

$$v_i = \bar{v}_i + v_i' \quad (3.15)$$

$$p = \bar{p} + p' \quad (3.16)$$

$$T = \bar{T} + T' \quad (3.17)$$

Uvrštavanjem jednadžbi (3.15) – (3.17) u polazne Navier-Stokesove jednadžbe uz primjenu pravila osrednjavanja i uz zanemarivanje utjecaja masenih sila dobiju se Reynoldosve osrednjene Navier-Stokesove jednadžbe (skraćeno RANS)

$$\frac{\partial}{\partial x_j}\left(\rho \bar{v}_j\right) = 0 \quad (3.18)$$

$$\frac{\partial}{\partial t}(\rho \bar{v}_i) + \frac{\partial}{\partial x_j}\left(\rho \bar{v}_i \bar{v}_j\right) = -\frac{\partial \bar{p}}{\partial x_i} + \frac{\partial}{\partial x_j}\left[\mu\left(\frac{\partial \bar{v}_j}{\partial x_i} + \frac{\partial \bar{v}_i}{\partial x_j}\right) - \rho\overline{v_i' v_j'}\right] \quad (3.19)$$

$$\frac{\partial}{\partial t}(\rho \bar{T}) + \frac{\partial}{\partial x_j}\left(\rho \bar{v}_j \bar{T}\right) - \frac{\partial}{\partial x_j}\left(\frac{\lambda}{c}\frac{\partial \bar{T}}{\partial x_j} - \rho\overline{v_j' T'}\right) = S_T \quad (3.20)$$

gdje je S_T izvorski član temperaturne jednadžbe, a prikazan je izrazom (3.21).

$$S_T = \frac{\mu}{c}\left(\frac{\partial v_i}{\partial x_j} + \frac{\partial v_j}{\partial x_i}\right)\frac{\partial v_i}{\partial x_j} \quad (3.21)$$

U Reynoldsovim osrednjenim Navier-Stokesovim jednadžbama javljaju se dva dodatna člana kojima se turbulentno strujanje razlikuje od laminarnog, a ti članovi su:

1) $-\rho\overline{v_i' v_j'}$ tenzor Reynoldsovih turbulentnih naprezanja i
2) $-\rho\overline{v_j' T'}$ vektor turbulentne difuzije temperature.

Kako su se vremenskim osrednjavanjem uveli novi članovi u jednadžbe, a time i nove nepoznanice potrebno je ponovno uskladiti broj nepoznanica i broj jednadžbi u sustavu. Pošto nije moguće egzaktno zatvoriti matematički model, odnosno uskladiti broj jednadžbi s brojem nepoznanica, ovisno o vrsti promatranog problema uvode se razni modeli turbulencija kojima se zaustavlja na određenoj korelaciji te se određene veličine aproksimiraju.

[10], [11], [12]

3.2 Modeli turbulencije

Model turbulencije može se definirati kao skup jednadžbi kojima se određuju dodatni članovi turbulencije u Reynoldsovim osrednjenim jednadžbama, a cilj im je zatvaranje sustava u matematičkom smislu. Ove jednadžbe mogu biti algebarske ili diferencijalne, a obično sadržavaju empirijske konstante ili funkcije. Prema tome modeli turbulencije ne opisuju detalje turbulentnog strujanja. Nadalje, modeli turbulencije mogu se podijeliti na modele prvog, drugog ili višeg reda gdje s porastom reda raste i razina točnosti modela turbulencije. Nedostaci modela turbulencija viših redova unatoč boljoj točnosti jesu visoki zahtjevi za memorijom i dugačko vrijeme rješavanja. U modelu turbulencije prvog reda modelira se korelacija za dodatne članove $\overline{v_i' v_j'}$ i $\overline{v_j' T'}$, dok se u modelima višeg reda rješavaju jednadžbe izrađene na temelju korelacija nižih redova. [16]

Tenzor Reynoldsovih turbulentnih naprezanja simetrični je tenzor drugog reda sa šest nepoznanica, a prema Bussinesqovoj hipotezi može ga se iskazati kao:

$$-\rho\overline{v_i' v_j'} = \mu_t\left(\frac{\partial \bar{v}_i}{\partial x_j} + \frac{\partial \bar{v}_j}{\partial x_i}\right) - \frac{2}{3}\rho\bar{k}\delta_{ij} \quad (3.22)$$

čime je 6 nepoznanica zamijenjeno jednom nepoznanicom μ_t koja označava polje turbulentne viskoznosti. Turbulentna viskoznost pri tome nije fizikalno svojstvo fluida već funkcija uvjeta strujanja, a prema kinetičkoj teoriji plinova možemo ju iskazati kao:

$$\mu_t = \rho l_t v_t \quad (3.23)$$

gdje je l_t put miješanja čestica u turbulentnom strujanju, a v_t brzina turbulentnih pulzacija.

Drugi član desne strane jednadžbe (3.22) tumači se kao tlak nastao uslijed turbulentnih pulzacija brzine te se u njemu javlja nova veličina $\bar{k}$ koja označava kinetičku energiju turbulencije odnosno energiju turbulentnih pulzacija brzine. Kinetičku energiju turbulencije možemo zapisati i kao:

$$\bar{k} = \frac{1}{2}\overline{v_t' v_t'} \quad (3.24)$$

Uvrštavanjem (3.22) u (3.19) i sređivanjem jednadžbe dobiva se konačni oblik jednadžbe količine gibanja:

$$\frac{\partial}{\partial t}(\rho\bar{v}_i) + \frac{\partial}{\partial x_j}(\rho\bar{v}_i\bar{v}_j) = -\frac{\partial\overline{p_e}}{\partial x_i} + \frac{\partial}{\partial x_j}\left[\mu_e\left(\frac{\partial\bar{v}_j}{\partial x_i} + \frac{\partial\bar{v}_i}{\partial x_j}\right)\right] \quad (3.25)$$

gdje je μ_e efektivna dinamička viskoznost dana jednadžbom (3.26) , a $\overline{p_e}$ efektivni tlak dan jednadžbom (3.27).

$$\mu_e = \mu + \mu_t \quad (3.26)$$

$$\overline{p_e} = \bar{p} + \frac{2}{3}\rho\bar{k} \quad (3.27)$$

Za vektor turbulentne difuzije u temperaturnoj jednadžbi uvodi se sljedeća pretpostavaka:

$$-\rho\overline{v_j'T'} = \frac{\mu_t}{\sigma_T}\frac{1}{Pr}\frac{\partial\bar{T}}{\partial x_j} \quad (3.28)$$

gdje je Pr Prandtlov broj dan izrazom (3.29), a σ_T Schmidtov broj za temperaturu koji predstavlja jednu od konstanti pojedinih modela turbulencije.

$$Pr = \frac{\mu c}{\lambda} \quad (3.29)$$

Uvrštavanjem (3.29) u (3.20) dobiva se izraz:

$$\frac{\partial}{\partial t}(\rho\bar{T}) + \frac{\partial}{\partial x_j}(\rho\bar{v}_j\bar{T}) - \frac{\partial}{\partial x_j}\left(\left(\mu + \frac{\mu_t}{\sigma_T}\right)\frac{1}{Pr}\frac{\partial\bar{T}}{\partial x_j}\right) = S_T \quad (3.30)$$

Za potrebe numeričke simulacije koja je daljnja tema ovog rada korišten je k-ω SST model turbulencije.

[10], [11], [12]

3.3 k-ω SST model turbulencije

k-ω SST model turbulencije sustav je dvije dopunske jednadžbe Reynoldsovim osrednjenim Navier-Stokesovim jednadžbama za slučaj turbulentnog strujanja gdje SST označava „The shear stress transport". Ovaj model hibridni je spoj *k-ε* i *k-ω* modela turbulencija pri čemu *k-ω* model turbulencija dobro simulira turbulentna strujanja u viskoznim podslojevima dok *k-ε* model turbulencije dobro simulira turbulencije daleko od zidova. Kao što je ranije navedeno *k* označava turbulentnu kinetičku energiju, a *ε* i *ω* redom označavaju disipaciju i specifičnu disipaciju turbulentne kinetičke energije.

Jednadžba turbulentne kinetičke energije:

$$\frac{\partial k}{\partial t} + U_j \frac{\partial k}{\partial x_j} = P_k - \beta^* k\omega + \frac{\partial}{\partial x_j}\left[(\nu + \sigma_k \nu_T)\frac{\partial k}{\partial x_j}\right] \quad (3.31)$$

Jednadžba brzine disipacije turbulentne kinetičke energije:

$$\frac{\partial \omega}{\partial t} + U_j \frac{\partial \omega}{\partial x_j} = \alpha S^2 - \beta \omega^2 + \frac{\partial}{\partial x_j}\left[(\nu + \sigma_\omega \nu_T)\frac{\partial \omega}{\partial x_j}\right] + 2(1 - F_1)\sigma_{\omega 2}\frac{1}{\omega}\frac{\partial k}{\partial x_i}\frac{\partial \omega}{\partial x_i} \quad (3.32)$$

Kako bi se osiguralo korištenje odgovarajućeg modela, funkcija miješanja F_1 (3.33), koja je sastavni dio jednadžbe brzine disipacije turbulentne kinetičke energije (3.32), određuje kada će se aktivirati *k-ω*, a kada *k-ε* model turbulencije. U slučaju graničnog sloja je F_1=1 dok je u slobodnoj struji daleko od stijenki F_1=0.

$$F_1 = tanh\left\{\left\{min\left[max\left(\frac{\sqrt{k}}{\beta^* \omega y}, \frac{500\nu}{y^2 \omega}\right), \frac{4\sigma_{\omega 2} k}{CD_{k\omega} y^2}\right]\right\}^4\right\} \quad (3.33)$$

U sustavu jednadžbi *k-ω* SST (3.31) i (3.32) nalazi se i druga funkcija miješanja F2 (3.35) , a sadržana je u izrazu za turbulentnu kinematičku viskoznost opisanom jednadžbom (3.34).

$$\nu_T = \frac{\alpha_1 k}{\max(\alpha_1 \omega, SF_2)} \quad (3.34)$$

$$F_2 = tanh\left[\left[max\left(\frac{2\sqrt{k}}{\beta^* \omega y}, \frac{500\nu}{y^2 \omega}\right)\right]^2\right] \quad (3.35)$$

Ograničenje smičnog naprezanja P_k dano relacijom (3.36), omogućava *k-ω* SST modelu turbulencije izbjegavanje nakupljanja suvišne turbulentne kinetičke energije u točkama stagnacije.

$$P_k = \min\left(\tau_{ij}\frac{\partial U_i}{\partial x_j}, 10\beta^* k\omega\right) \quad (3.36)$$

Pomoćni izrazi korišteni u jednadžbama (3.31) – (3.36) :

$$CD_{k\omega} = \max\left(2\rho\sigma_{\omega 2}\frac{1}{\omega}\frac{\partial k}{\partial x_i}\frac{\partial \omega}{\partial x_i}, 10^{-10}\right) \quad (3.37)$$

$$S_{ij} = \frac{1}{2}\left(\frac{\partial u_i}{\partial x_j} + \frac{\partial u_j}{\partial x_i}\right) \quad (3.38)$$

$$\tau_{ij} = \mu_t\left(2S_{ij} - \frac{2}{3}\frac{\partial u_k}{\partial x_k}\delta_{ij}\right) - \frac{2}{3}\rho k \delta_{ij} \quad (3.39)$$

$$\phi = \phi_1 F_1 + \phi_2(1 - F_1) \quad (3.40)$$

Koeficijenti korišteni u jednadžbama i pomoćnim izrazima :

$$\alpha_1 = \frac{5}{9}$$

$$\alpha_2 = 0.44$$

$$\beta_1 = \frac{3}{40}$$

$$\beta_2 = 0.0828$$

$$\beta^* = \frac{9}{100}$$

$$\sigma_{k1} = 0.85$$

$$\sigma_{k2} = 1$$

$$\sigma_{\omega 1} = 0.5$$

$$\sigma_{\omega 2} = 0.856$$

[10], [13], [14]

3.4 Rubni uvjeti

Osim osnovnih i dopunskih jednadžbi zadanih u obliku zakona svojstvenih određenim oblicima strujanja te modela turbulencije korištenih za jednoznačno određivanje rješenja i potpuno zatvaranje matematičkog modela potrebno je zadati i početne i rubne uvjete strujanja.

Rubni uvjeti postavljaju se na granicama domene strujanja, a mogu biti različiti po tipu. Četiri najčešća tipa rubnih uvjeta (također upotrijebljena za postavljanje simulacije koja je daljnja tema ovog rada) su ravnina simetrije, ulazna granica, izlazna granica i zid.

Rubni uvjeti unutar ova 4 tipa koji se mogu postaviti na granicama također se dijele na dva osnovna tipa iz kojih se mogu dobiti različiti izvedeni oblici. Jedan je takozvani Dirichletov rubni uvjet kojim se propisuje vrijednost varijable na granici domene. Drugi je von Neumannov rubni uvjet koji propisuje vrijednost nultog gradijenta na granici.

Ulazna granica fizikalno označava ulaz fluida u domenu te su u ovom području proračuna poznate sve veličine. Konvekcijski protoci se pri tome mogu lako izračunati dok su difuzijski protoci obično nepoznati, ali se mogu aproksimirati koristeći poznate vrijednosti varijabli i jednostrane aproksimacije. Na ulazu brzina je najčešće zadana s Dirichletovim rubnim uvjetom, a tlak s von Neummanovim rubnim uvjetom.

Izlazna granica fizikalno označava izlaz fluida iz domene, a strujanje na tom rubu treba biti usmjereno izvan područja proračuna i po mogućnosti treba biti paralelno. Na ovom se rubu najčešće postavlja von Neummanov rubni uvjet i za brzinu i za tlak.

Zid predstavlja nepropusnu granicu, a budući da nema strujanja kroz zid konvekcijski protoci svih veličina jednaki su nuli. Difuzijski protoci za skalarne veličine poput unutarnje energije mogu biti jednaki nuli, a takve rubne uvjete nazivamo adijabatskim zidom, mogu biti zadani npr. zadan protok topline kroz zid ili mogu biti zadane vrijednosti varijabli na primjer zid konstantne temperature. U viskoznom je strujanju brzina fluida na zidu jednaka brzini zida

odnosno nuli za mirujući zid jer se fluid lijepi uz čvrstu stijenku. Derivacija brzine u smjeru zida (tangente) je također jednak nuli.

Rubni uvjet simetrije koristi se kada postoji ravnina simetrije na strujanje. Na ravnini simetrije su konvektivni protoci svih varijabli jednaki nuli, slično kao i na zidu. Derivacije tangencijalne komponente brzine i svih skalarnih veličina u smjeru normale su također jednaki nuli. Iako je normalna komponenta brzine jednaka nuli, njena derivacija u smjeru normale nije te zbog toga niti normalno naprezanje na ravnini simetrije nije jednako nuli. Rubni uvjet simetrije uvelike smanjuje vrijeme proračuna jer se na taj način domena nekog simetričnog strujanja može smanjiti dva puta.

[11], [12]

4. NUMERIČKA SIMULACIJA HLAĐENJA BATERIJSKOG MODULA

4.1 Referentni zrakoplov [15]

Kao referentni zrakoplov za potrebe ovog rada korišten je zrakoplov Extra 330LE Electric Aircraft sa Siemensovim elektromotorom SP260D. Zrakoplov i njegov pogonski sustav prikazani su na slici 4.1.

Potrebni podaci uzeti su kao početni uvjeti za dimenzioniranje pogonskog baterijskog paketa zrakoplova, a navedeni su u tablicama 4.1 – 4.3.

Slika 4.1 Električni zrakoplov Extra 330LE [15]

Tablica 4.1 Karakteristike zrakoplova Extra 330LE Electric Aircraft

Duljina	7,5 m
Visina	2,6 m
Raspon krila	8 m
Površina krila	10,84 m^2
Maksimalna težina	950 kg
Maksimalna brzina	337.5 km/h (postignuta)
Maksimalna brzina penjanja	11.5 m/s

Tablica 4.2 Karakteristike elektromotora SP260D

Maksimalna snaga	260 kW
Kontinuirana snaga	230 kW
Maksimalni kontinuirani broj okretaja	2500 okr./min
Kontinuirani moment	1000 Nm
Napon	580 V
Težina motora s propelerom	50 kg
Maksimalna temperatura na ulazu	90 °C
Učinkovitost	95%

Tablica 4.3 Karakteristike pogonskog baterijskog paketa

Vrsta baterije	Li-Ion
Broj paketa	2
Broj modula po paketu	14
Ukupni kapacitet	18.6 kWh

4.2 Odabir baterijskih ćelija

Kao referentna baterijska ćelija uzeta je baterija Samsung 21700-48G čiji je operativni temperaturni raspon:

- punjenje: od 0 °C do 50 °C
- pražnjenje: od -20 °C do 60 °C

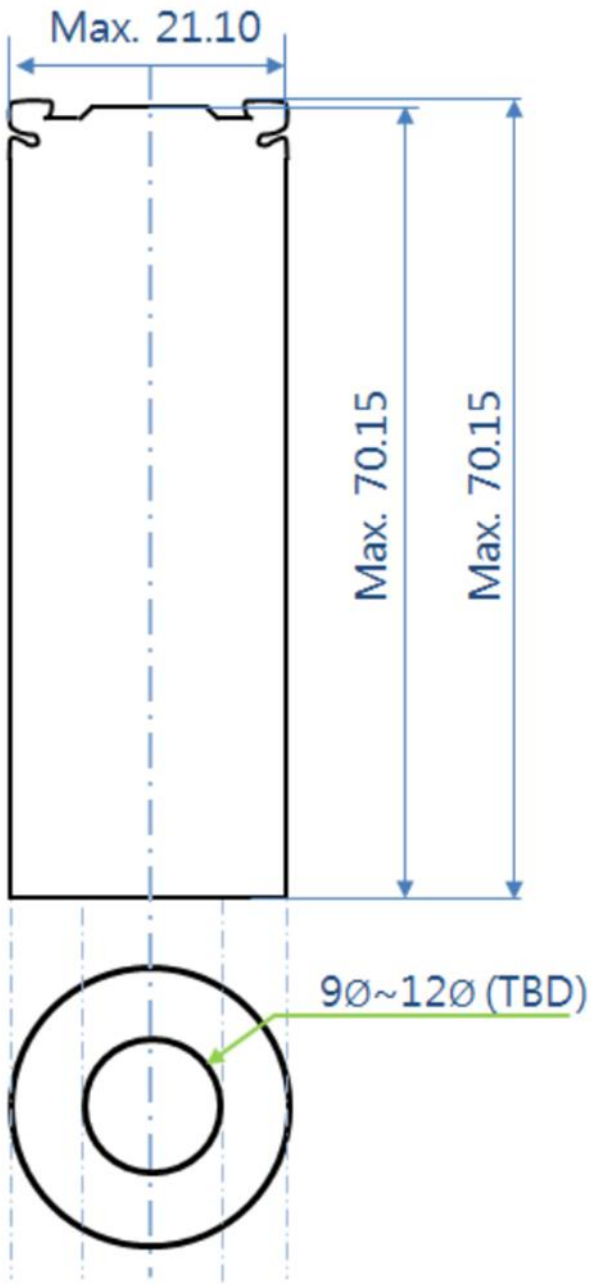

Slika 4.2 Geometrija i dimenzije baterijske ćelije Samsung 21700-48G [16]

Geometrija i dimenzije ćelije prikazani su na slici 4.2, a njezine termodinamičke značajke dane su u tablici 4.4. [16]

Dimenzije:

- maksimalni promjer: 21.10 mm
- maksimalna visina: 70.15 mm

Tablica 4.4 Termodinamičke značajke baterijske ćelije Samsung 21700-48G

Gustoća [kg/m^3]	2303
Specifični toplinski kapacitet [J/kgK]	900
Toplinska provodnost (aksijalna)	29.7
Toplinska provodnost (tangencijalna)	0.429
Generirana toplina po ćeliji [W]	5
Specifična generirana toplina [W/m^3]	207524.8511

Karakteristike baterijske ćelije potrebne za dimenzioniranje baterijskog paketa i njegovih modula koji bi zadovoljavali potrebe referentnog zrakoplova dani su u tablici 4.5 a preuzeti su iz [10]. Električna energija koja se crpi iz pojedine ćelije dobivena je zatim prema formuli:

$$E_{ćelija} = U_{nom} C_{nom} \quad (4.1)$$

Tablica 4.5 Karakteristike baterijske ćelije

U_{max} [V]	4,2
U_{nom} [V]	3,6
C_{nom} [Ah]	4,8
I_{max} (DCH) [A]	9,6
I_{max} (CH) [A]	4,8
$E_{ćelija}$ [kWh]	0,01728

4.3 Dimenzioniranje modula pogonskog baterijskog paketa

Prema zahtjevima određenim na temelju referentnog zrakoplova i prema podacima za baterijsku ćeliju opisanim u prethodnom odlomku, od baterijskih ćelija, njihovih veza i kućišta sastavljen je baterijski modul. Modul se sastoji od 40 cilindričnih Li-ionskih ćelija međusobno spojenih u 5 serija i 8 paralela, a prikazan je na slici 4.3. Karakteristike paketa i modula dane su u tablici 4.6.

Slika 4.3 Serijski i paralelni spoj ćelija u modulu

Konstrukcija modula sastoji se od dva ulaza i dva izlaza za zrak, kućišta koje prati raspored baterijskih ćelija i odstojnika za pozicioniranje baterijskih ćelija unutar modula kako bi se spriječilo međusobno doticanje ćelija i omogućio nesmetan protok zraka između njih. Na slikama 4.4 i 4.6 prikazani su produženi ulazni i izlazni kanali napravljeni za potrebe simulacije kako bi se osigurao ulaz u modul već razvijenog strujanja zraka.

Tablica 4.6 Karakteristike baterijskog modula

E_{paket} [kWh]	18.6
U_{paket} [V]	290
E_{modul} [kWh]	0.6643
Borj ćelija u modulu: $n_{ćelija}$	40
U_{modul} [V]	20.7
Broj serija	5
Broj paralela	8
P_{modul} [kW]	1.9929

Nakon što je određen broj potrebnih serija i paralela modula izrađena je geometrija kako je prikazano na slikama 4.4 – 4.6 . Za izradu geometrije modula korišten je Ansys Space Claim.

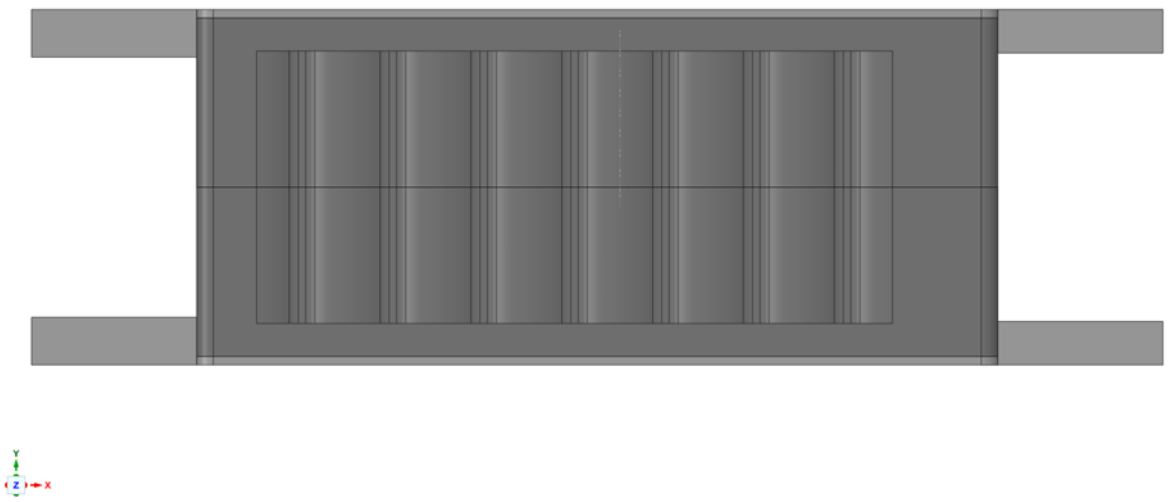

Slika 4.4 Kućište modula (1)

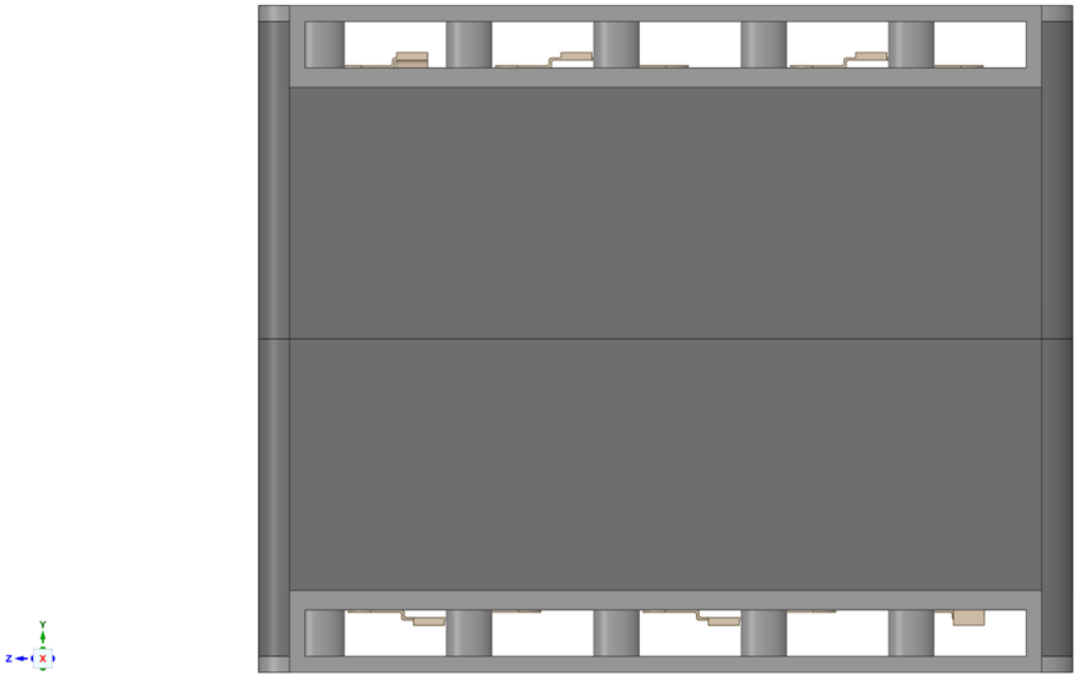

Slika 4.5 Kućište modula (2)

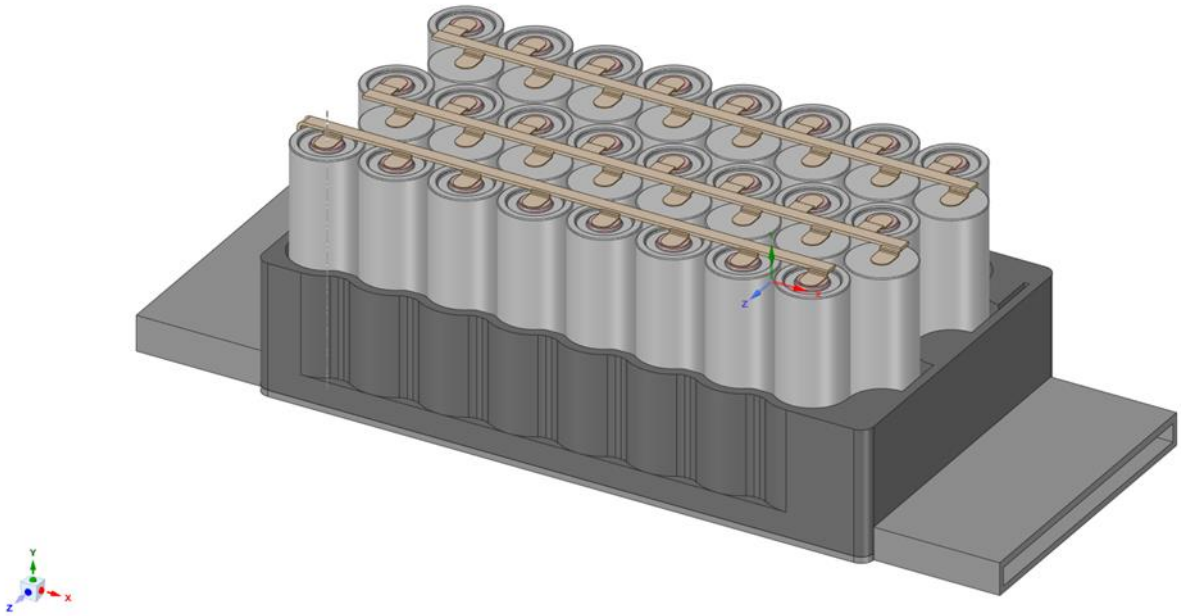

Slika 4.6 Dio kućišta modula s baterijama

Kako bi se smanjio broj konačnih volumena, a time i samo vrijeme potrebno za proračun, korištena je pojednostavljena geometrija. Strujanje i prijenos topline simulirani su na dijelu geometrije sa dodanim uvjetima simetrije na presjecima. U geometriji su pri tome zanemarene interkonekcije te odstojnici za pozicioniranje ćelija unutar modula. Pojednostavljena geometrija korištena za simulaciju u konačnici sastavljena je od 16 polovičnih ćelija i okolnog fluida kako prikazuje slika 4.7.

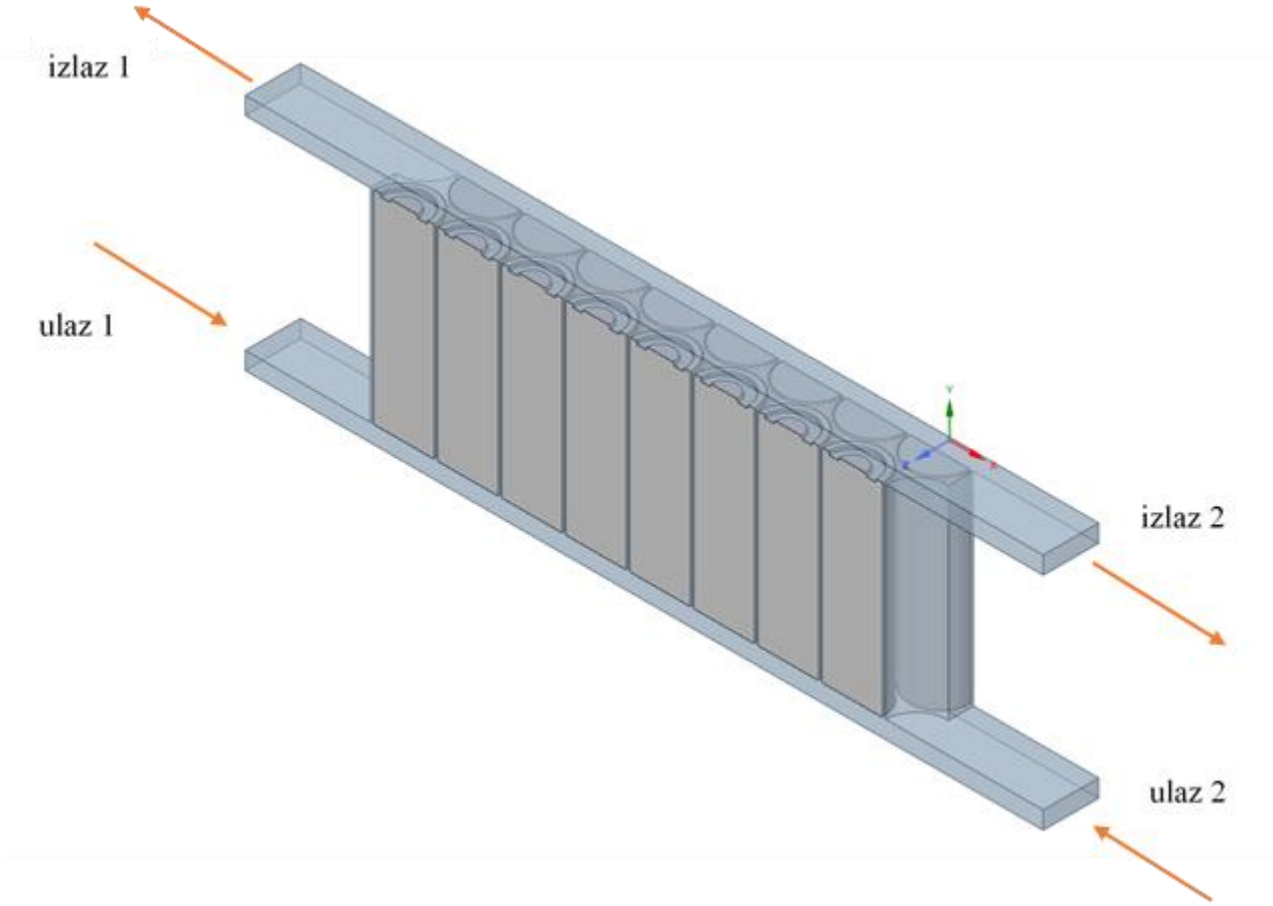

Slika 4.7 Pojednostavljena geometrija

Simulacija je provedena za dvije slične geometrije od kojih jedna ima uniforman razmak između ćelija u iznosu od 1 mm , a druga neuniforman. Raspored neuniformnih razmaka dan je u tablici 4.7 a prikazan je na slici 4.8.

Tablica 4.7 Raspored neunifomnih razmaka između ćelija

Razmak između ćelija:	Razmak [mm]
1 i 2	1
2 i 3	1
3 i 4	1.5
4 i 5	2
5 i 6	1.5
6 i 7	1
7 i 8	1

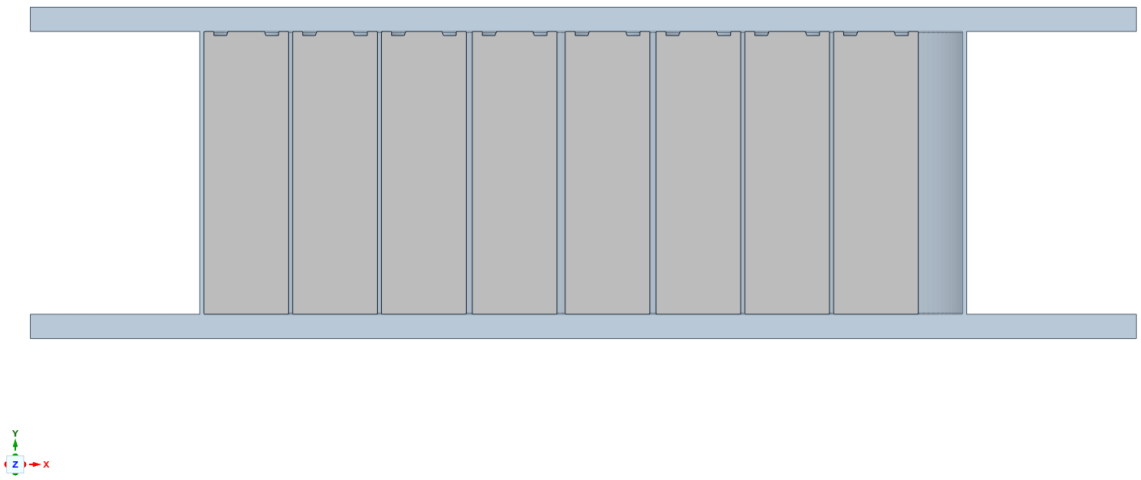

Slika 4.8 Pojednostavljena geometrija s neuniformnim razmacima između ćelija

Cilj ovakvog rasporeda neuniformnih razmaka između ćelija jest poboljšanje protoka na mjestima visokog tlaka gdje je protok zagušen povećanjem razmaka između ćelija za 50% i 100% s obzirom na ćelije bliže ulazima odnosno izlazima.

4.4 Mreža

Za potrebe izrade mreže konačnih volumena korišten je Ansys Mesher programski paket. Mreža je nestrukturirana, a sastavljena je od približno 8 milijuna konačnih volumena. Detaljniji podaci o broju i vrsti konačnih volumena po regiji dani su u tablici 4.8. Dvije mreže napravljene su sa sličnim brojem konačnih volumena kako bi rezultati bili usporedivi.

U području oko zidova korištena je finija mreža kako bi se lakše i točnije simulirali rubni uvjeti strujanja i konvektivnog prijenosa topline. Na strani fluida, rezultirajuća finija mreža napravljena je pomoću 4 sloja volumena čiji rast iznosi 1,1 , a sa strane baterijskih ćelija postavljena mreža napravljena je od 3 sloja volumena istog iznosa rasta. Korištena mreža i njezine karakteristike prikazane su na slikama 4.9 – 4.11.

Tablica 4.8 Mreža konačnih volumena

Geometrija	Regija	Broj prizmi po regiji	Broj tetraedara po regiji	Ukupni broj konačnih volumena po regiji	Ukupan broj konačnih volumena
Geometrija s uniformnim razmakom između ćelija	zrak	1410248	2076991	3487239	8029470
	ćelije	848361	3693870	4542231	
Geometrija s neuniformnim razmakom između ćelija	zrak	1882692	2788606	4671298	8849212
	ćelije	1255695	2922219	4177914	

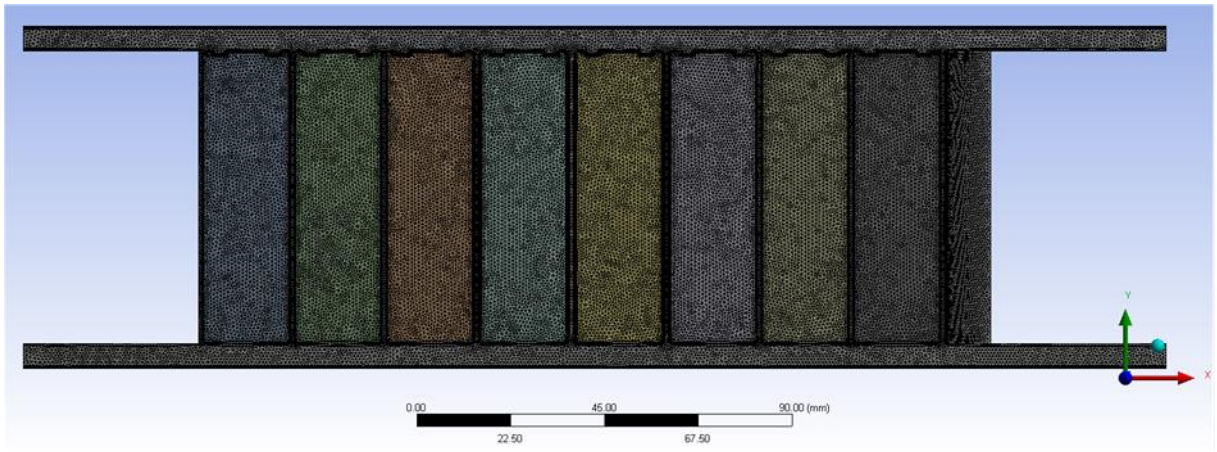

Slika 4.9 Mreža konačnih volumena

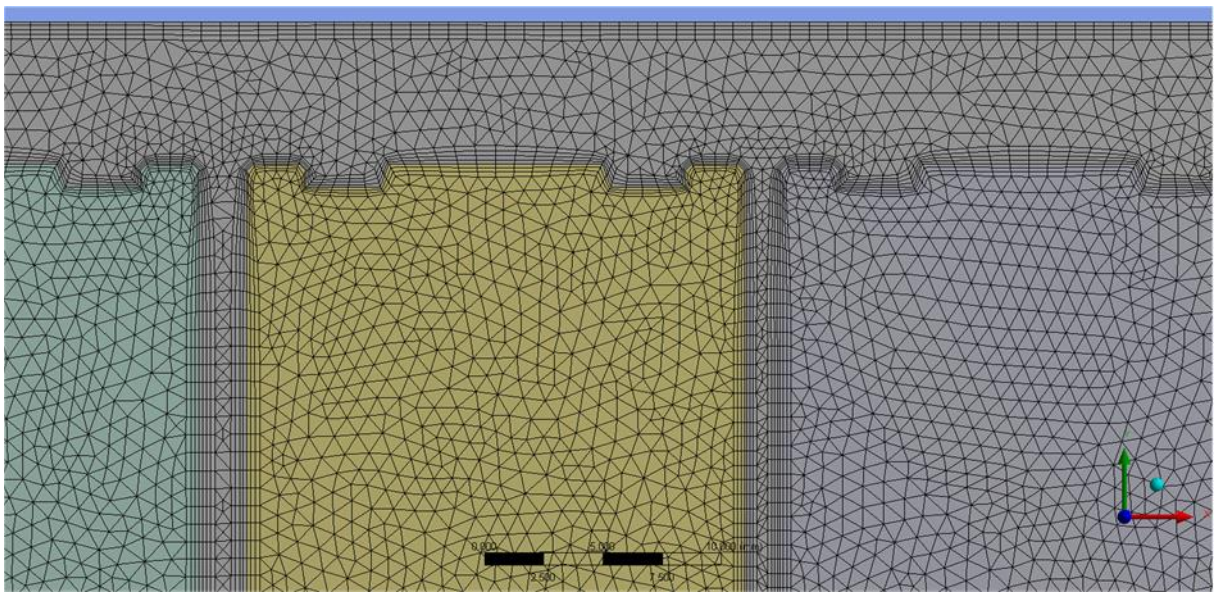

Slika 4.10 Detaljniji prikaz mreže na rubovima zrak/ćelija

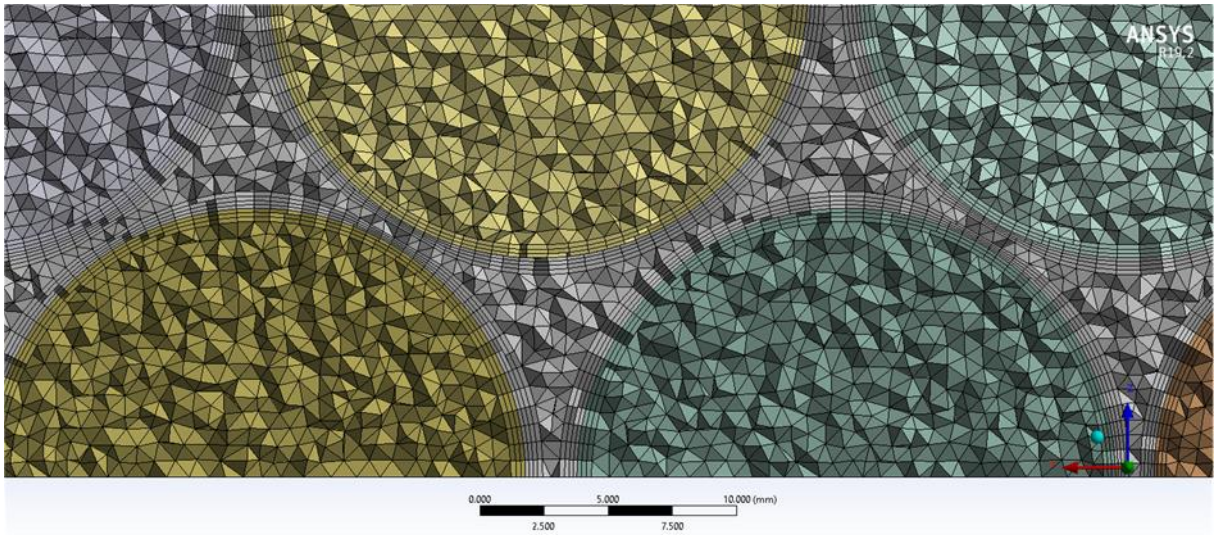

Slika 4.11 Prikaz mreže u poprečnom presjeku

Mreža napravljena pomoću Ansys Mesher-a konvertirana je u OpenFoam pomoću funkcije „fluent3DMeshToFoam“. Rezultati provjere za maksimalnu neortogonalnost konačnih volumena te maksimalno skošenje po regiji za obje mreže dani su u tablici 4.9.

Tablica 4.9 Maksimalna neortogonalnost i maksimalno skošenje konačnih volumena

Geometrija	Regija	Maksimalna neortogonalnost	Maksimalno skošenje
Geometrija s uniformnim razmakom između ćelija	zrak	68.076872	2.3340827
	ćelije	69.81076	2.2272967
Geometrija s neuniformnim razmakom između ćelija	zrak	68.452746	2.3344725
	ćelije	61.348828	2.324633

4.5 Početni i rubni uvjeti

Zbog toga što simulacija nije rađena za cijelu geometriju baterijskog modula već za njezin isječak, najprije su zadani rubni uvjeti simetrije na fluidu i ćelijama. Na mjestu dodira fluida i ćelija postavljen je uvjet „mappedWall" u OpenFoam-u te je na taj način osigurana komunikacija između mreža konačnih volumena za dvije odvojene regije.

Za postavljanje početnih uvjeta izračunate su početne vrijednosti turbulentne kinetičke energije k i specifične brzine disipacije turbulentne kinetičke energije ω. Za izračunavanje relevantnih parametara korištene su sljedeće formule:

$$k = \frac{3}{2}\left(I\left|u_{ref}\right|\right)^2 \quad (4.2)$$

$$\omega = \frac{k^{0.5}}{C_u L} \quad (4.3)$$

gdje je I intenzitet turbulencije, C_u je konstanta i jednaka je 0.09, a L je referentna dužina. Početni uvjeti strujanja za dvije ispitivane brzine dani su u tablici 4.10 .

Tablica 4.10 Početni uvjeti strujanja

Brzina [m/s]	Protok [l/s]	Re_{inlet}	k [J/kg]	ω [1/s]
20 (72 km/h)	9.144	13822	1.500	1687.673
40 (144 km/h)	18.288	27645	6.000	3375.347

Za potrebe simulacije prijenosa topline također je potrebno zadati početnu temperaturu ćelije i ulaznu temperaturu fluida. Za sve provedene simulacije postavljeni su isti početni uvjeti, odnosno početna temperatura baterijskih ćelija od 30 °C i temperatura zraka na ulazu od 20 °C.

5. REZULTATI

Simulacija hlađenja baterijskog modula provedena je pomoću chtMultiRegionSimpleFoam solvera koji je dio OpenFoam programskog paketa. Ovaj solver definiran je pomoću ranije navedenog matematičkog modela u poglavlju 3. Ukupno su provedene tri simulacije. Dvije za istu geometriju koja se odnosi na modul s uniformnim razmakom između ćelija s različitim protocima te jedna za geometriju sličnu prvoj no s neuniformnim razmacima između ćelija opisanih u prethodnom poglavlju. Protok kod treće simulacije s neuniformnim razmakom između ćelija odgovara slučaju manjeg proračuna kod geometrije s uniformnim razmakom između ćelija. Svi ostali parametri u sve tri simulacije jednaki su te stoga usporedivi. Kako je prethodno rečeno za slučaj uniformnog razmaka između baterijskih ćelija u modulu provedene su dvije simulacije sa različitim protocima zraka. Jedan protok pri tome odgovara brzini zraka na ulazu od 20 m/s dok drugi protok zraka odgovara duplo većoj brzini.

Kako bi se potvrdila konvergencija rezultata simulacije osim konvergencije reziduala bitnih parametara simulacije kao što su tlak, brzina, turbulentna kinetička energija, entalpija, itd. također je praćena i konvergencija prosječne temperature ćelija i zraka. Prikazi konvergencija prosječne temperature ćelija u modulu za sve tri simulacije dani su na slikama 5.1 – 5.3 . Iz slika je vidljivo kako je za konvergenciju rezultata bilo potrebno približno 40 000 iteracija. Na slikama 5.1 i 5.2 koje prikazuju konvergenciju prosječne temperature ćelija za modul s uniformnim razmakom između ćelija za oba protoka vidljive su točke nagle promjene nagiba krivulje. Na slici 5.1 krivulja dvaput mijenja nagib i to oko 1000. i 8000. iteracije, a na slici 5.2 jedanput oko 7000. iteracije. Ove promijene odgovaraju promjeni podrelaksacijskih faktora vezanih za energetsku jednadžbu (u ovom slučaju entalpiju) tijekom simulacije. Podrelaksacijski faktori entalpije za energetsku jednadžbu ćelija u oba slučaja postavljeni su na 0.9 te su u prvom slučaju dva puta povećani prvo na 0.91 te zatim 0.93 čime se ubrzala konvergencija i time skratilo vrijeme trajanja simulacije. U drugom slučaju koji odgovara slici 5.2, podrelaksacijski faktor promijenjen je jednom s 0.9 na 0.93. Na slici 5.3 prikazana je konvergencija prosječne temperature ćelija za modul s neuniformnim razmakom između ćelija, a zbog nestabilnosti simulacije pri većim podrelaksacijskim faktorima za entalpiju ćelija, njezin iznos držan je stalnim na 0.89.

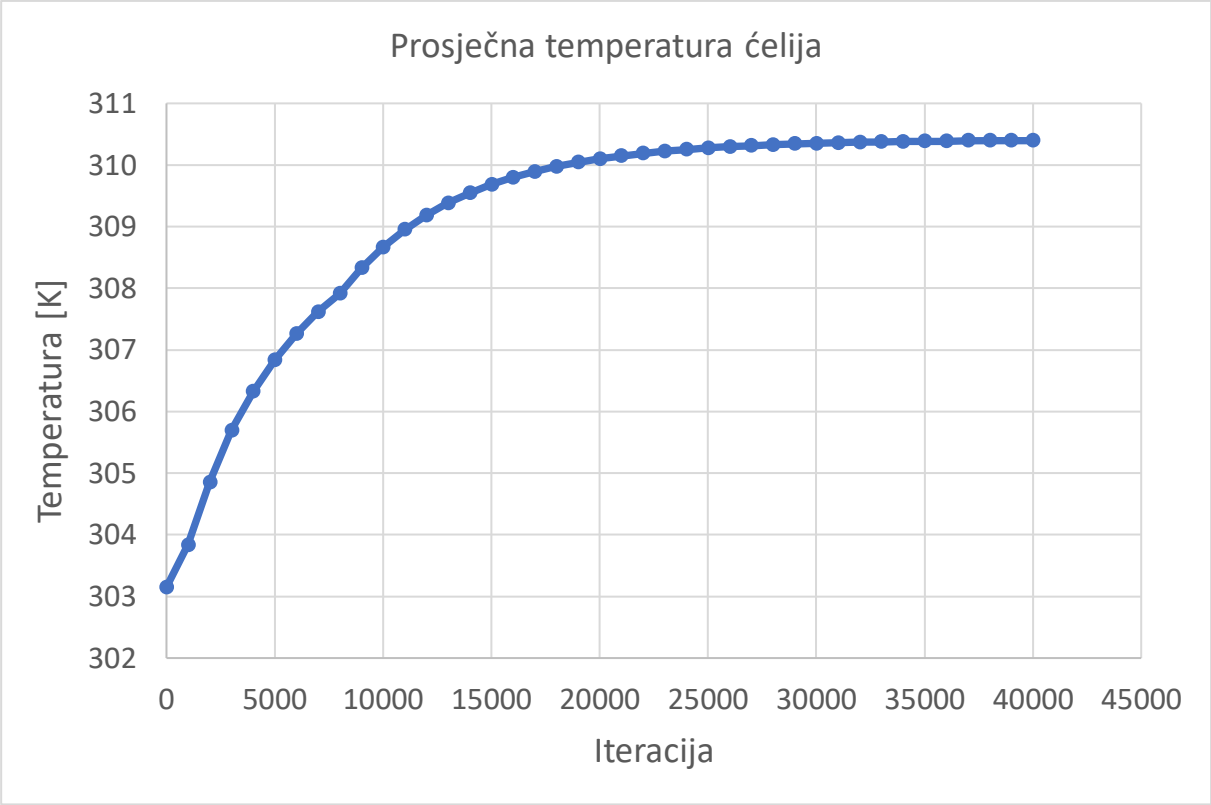

Slika 5.1 Konvergencija prosječne temperature ćelija u modulu s uniformnim razmakom između ćelija i brzinom zraka na ulazima od 20 m/s

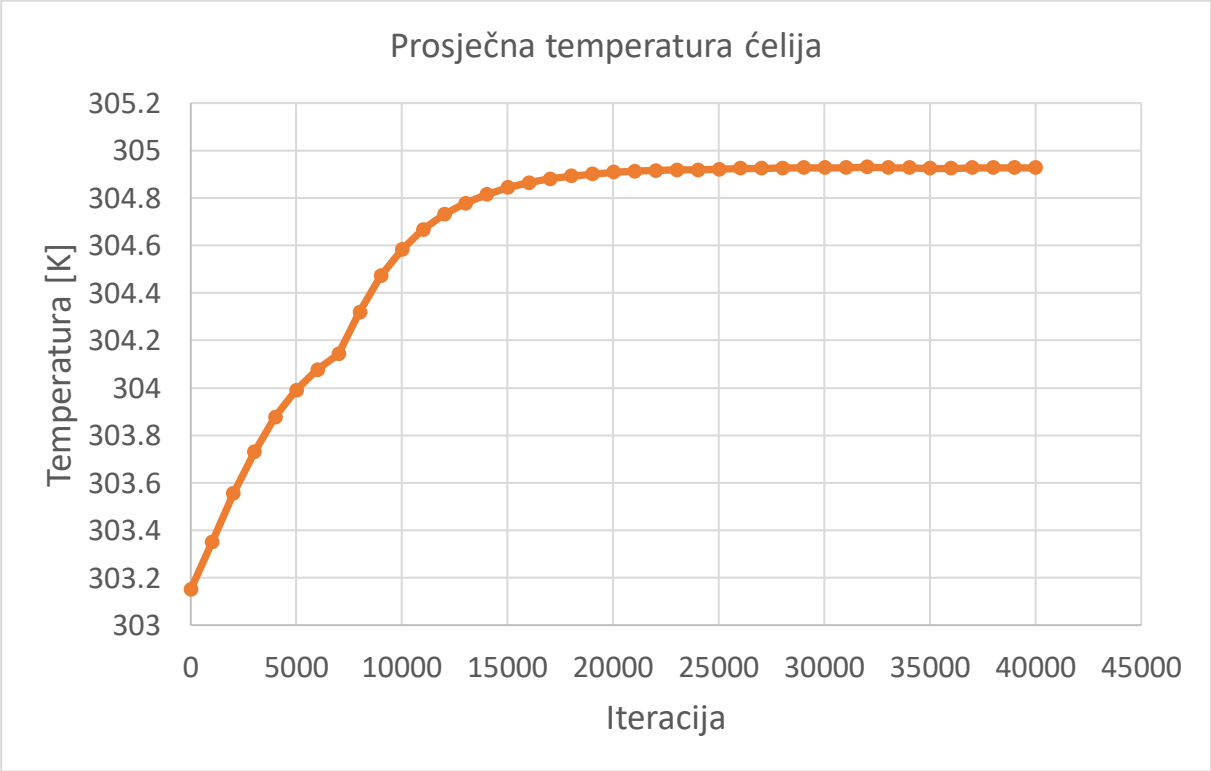

Slika 5.2 Konvergencija prosječne temperature ćelija u modulu s uniformnim razmakom između ćelija i brzinom zraka na ulazima od 40 m/s

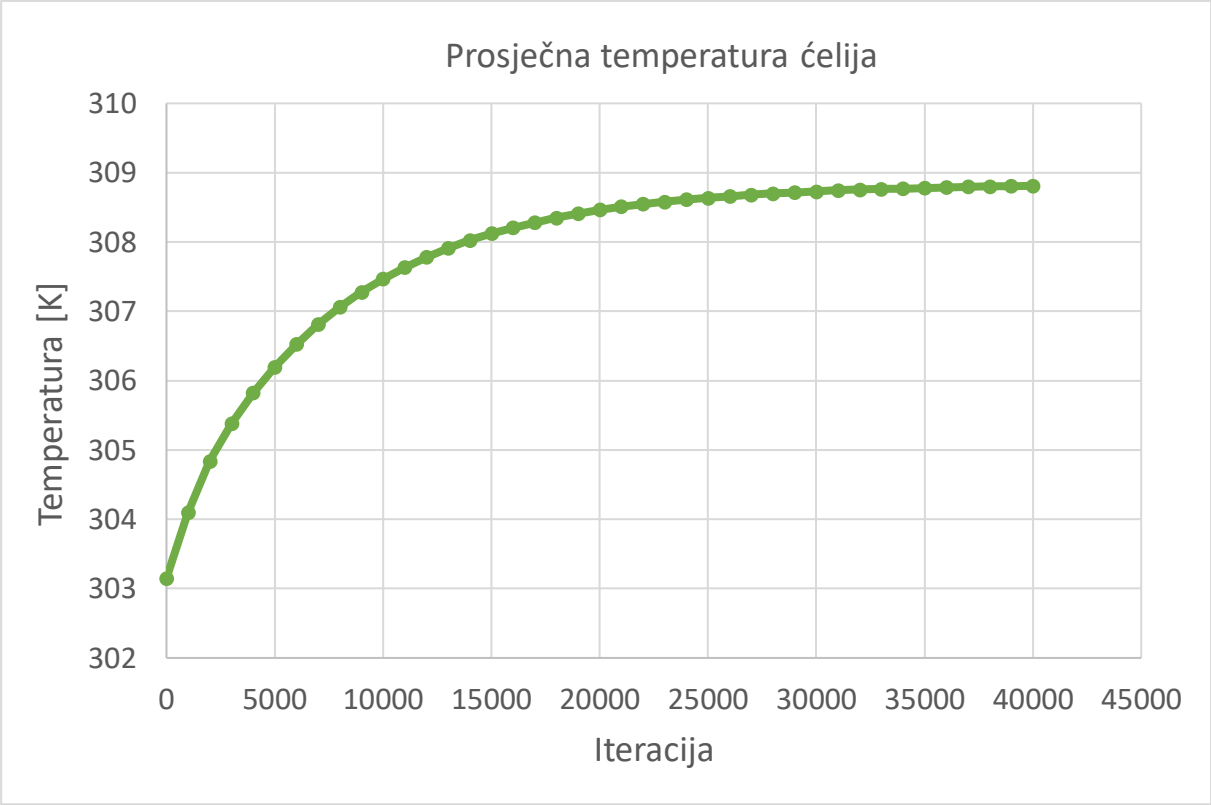

Slika 5.3 Konvergencija prosječne temperature ćelija u modulu s neuniformnim razmakom između ćelija

5.1 Utjecaj promjene protoka zraka na hlađenje baterijskog modula

U tablici 5.1 dani su rezultati za maksimalnu i prosječnu temperaturu ćelija te maksimalnu temperaturnu razliku u modulu.

Tablica 5.1 Temperaturno stanje ćelija pri hlađenju s uniformnim razmakom između ćelija

Brzina [m/s]	Maksimalna temperatura u ćeliji [°C]	Prosječna temperatura ćelije [°C]	Maksimalna razlika temperatura unutar modula [°C]
20	44.89	37.25	19.16
40	37.79	31.77	14.48

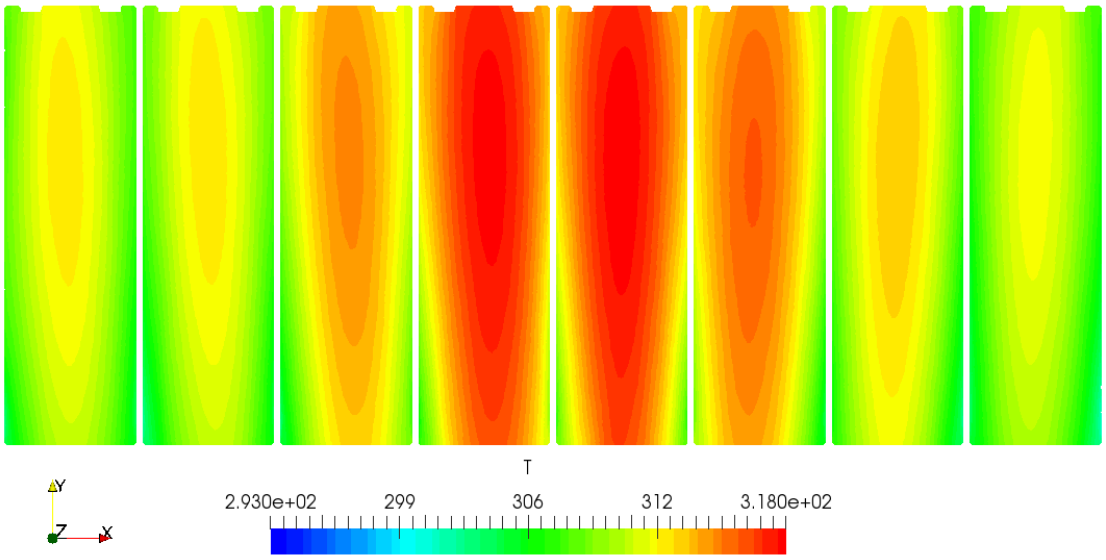

Slika 5.4 Temperaturno polje [K] ćelija pri brzini strujanja na ulazu od 20 m/s i uniformnim razmakom između ćelija

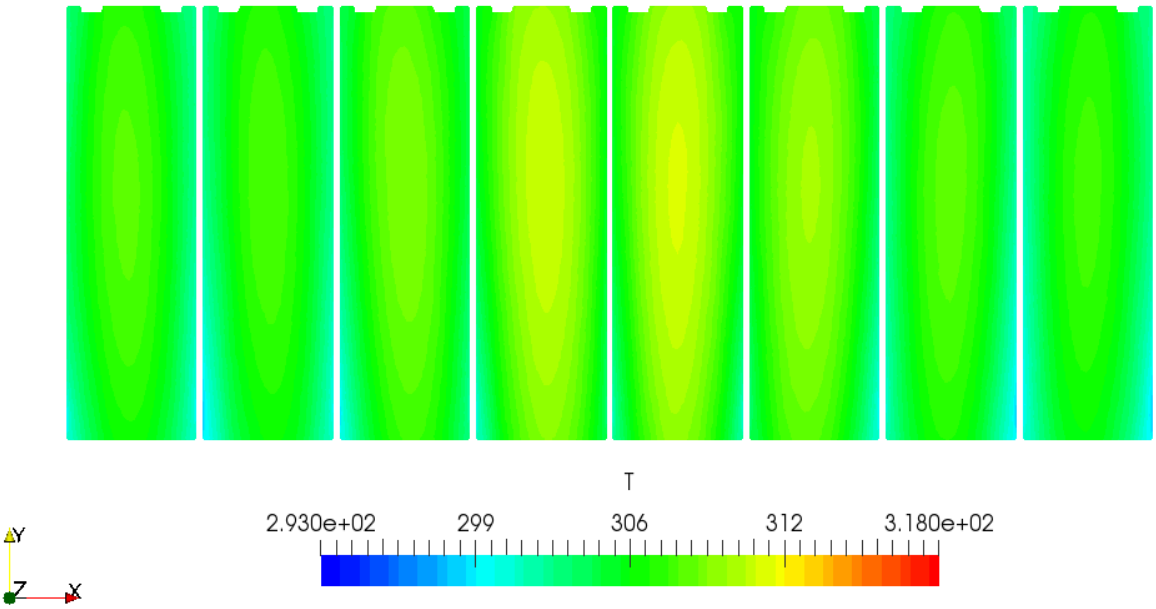

Slika 5.5 Temperaturno polje [K] ćelija pri brzini strujanja na ulazu od 40 m/s i uniformnim razmakom između ćelija

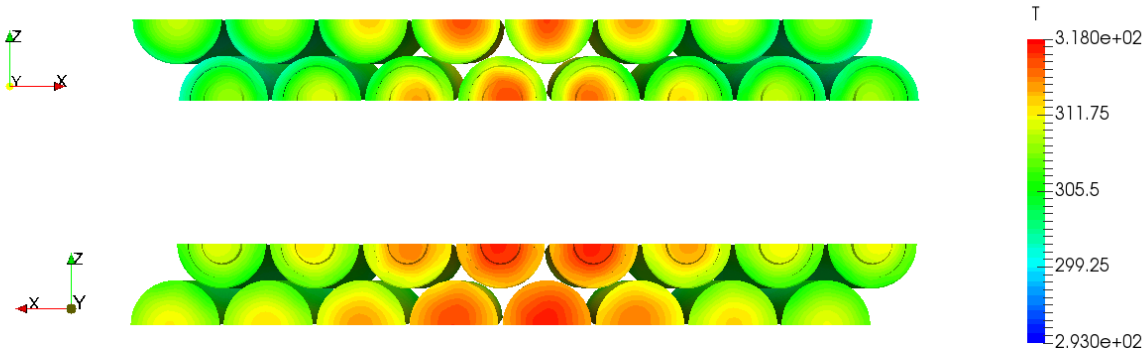

Slika 5.6 Temperaturno polje [K] ćelija pri brzini strujanja na ulazu od 20 m/s i uniformnim razmakom između ćelija –strana ćelija bliže ulazima (gornja slika) i strana ćelija bliže izlazima (donja slika)

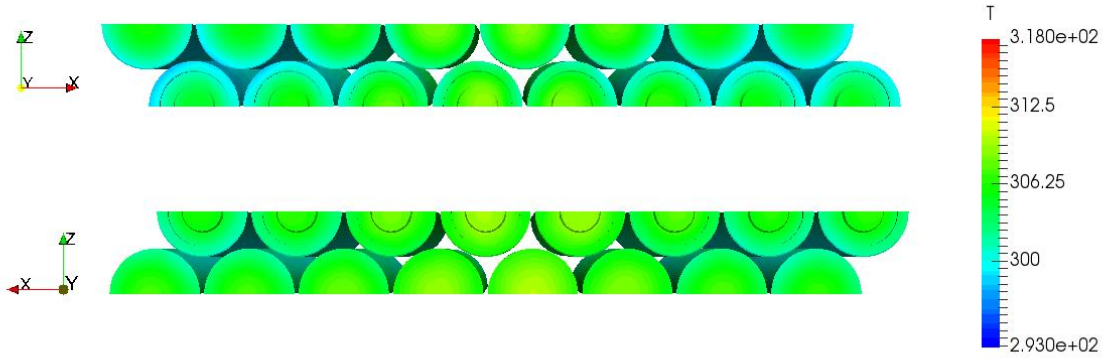

Slika 5.7 Temperaturno polje [K] ćelija pri brzini strujanja na ulazu od 40 m/s i uniformnim razmakom između ćelija –strana ćelija bliže ulazima (gornja slika) i strana ćelija bliže izlazima (donja slika)

Usporedbom rezultata prikazanih u tablici 5.1 vidljivo je da je porastom protoka zraka kroz modul maksimalna temperatura ćelija smanjena za 7.1 °C, a prosječna temperatura ćelije za 5.48 °C. Također usporedbom maksimalnih temperaturnih razlika koje se javljaju unutar modula vidljivo je da je povećanjem protoka ta razlika smanjena za 4.68 °C. Preračunato u postotke dobivamo smanjenja maksimalne temperature od 15.8% , prosječne temperature ćelija od 14.7% i maksimalne temperaturne razlike unutar modula od 24.4%. Usporedbom

ovih postotaka vidljivo je da je najveća prednost povećanja protoka u ovom slučaju kod postizanja bolje temperaturne uniformnosti modula. Temperaturno polje u ćelijama za ova dva slučaja prikazano je na slikama 5.4 – 5.7, a temperaturna skala dana je u [K].

U tablici 5.2 dani su podaci o padu tlaka kroz simulirano područje i prosječnim promjenama temperature zraka na izlazima s obzirom na ulaznu temperaturu od 20 °C. Pad tlaka pri tome izračunat je kao razlika između prosječnog tlaka na ulazu i tlaka na izlazu, a srednja temperatura na izlazima na principu „Surface average“.

Tablica 5.2 Stanje zraka pri hlađenju s uniformnim razmakom između ćelija

Brzina [m/s]	Pad tlaka [kPa] ulaz 1 – izlaz 1	Pad tlaka [kPa] ulaz 2 – izlaz 2	Prosječna promjena temperature na izlazu 1 [°C]	Prosječna promjena temperature na izlazu 2 [°C]
20	0.367	0.364	7.96	8.05
40	1.242	1.229	3.91	3.99

Iz tablice 5.2 vidljivo je da je dvostrukim povećanjem protoka zraka kroz modul pad tlaka povećan za 0.875 kPa na dijelu ulaz 1 –izlaz 1 odnosno za 0.865 kPa na dijelu ulaz 2 - izlaz 2. Prosječna promjena temperature na izlazu 1 smanjena je za 4.05 °C, a na izlazu 2 za 4.06 °C. Pad tlaka povećan je približno 3.38 puta kako na dijelu ulaz 1 – izlaz 1 tako i na dijelu ulaz 2 – izlaz 2. Razlika prosječnih promjena temperature zraka na izlazima 1 i 2 smanjena je 50.9% i 50.4%.

Na slikama 5.8 i 5.9 prikazana su polja tlaka za oba slučaja. Iz slika je vidljivo da je područje najvišeg tlaka na sredini između dva ulaza u modul. Povećan tlak na tom području smanjuje protok između srednjih ćelija modula te se zbog toga srednje ćelije hlade slabije u odnosu na ćelije bliže ulazima/izlazima . Posljedica tog povećanja tlaka dobro se primjećuje na slici 5.4, a slabije na slici 5.5 zbog sveukupno boljeg hlađenja unatoč većeg protoka zraka.

Snaga potrebna za svladavanje pada tlaka u simuliranom području za oba slučaja dobivena je prema formuli:

$$P = \Delta p Q \quad (5.1)$$

gdje je Δp ukupni pad tlaka, a Q ukupni volumni protok zraka na simuliranom području. Potrebna snaga u stvarnosti još je i veća zbog gubitaka koji nisu uključeni u ovom proračunu.

Tablica 5.3 Potrebna snaga za svladavanje pada tlaka u modulu

Protok [l/s]	Ukupni pad tlaka [kPa]	Snaga [W]
9.144	0.731	6.684
18.288	2.471	45.189

Iz tablice 5.3 vidljivo je da je za svladavanje pada tlaka na simuliranom području modula potrebno 6.684 W snage pri protoku koji odgovara ulaznoj brzini od 20 m/s, dok je za protok koji odgovara ulaznoj brzini od 40 m/s potrebna snaga za svladavanje tlaka na simuliranom području od 45.189 W. Potrebna snaga bez gubitaka za cijeli modul 5 puta je veća nego za simulirano područje. Za svladavanje pada tlaka kroz modul, pri manjem protoku potrebna je snaga od 33.42 W, dok je za veći protok potrebna snaga od 225.945 W. Dvostruko povećanje protoka zraka u modulu prema tome zahtjeva 6.76 puta više snage za hlađenje modula. Usporedimo li potrebnu snagu za svladavanje pada tlaka u modulu s ukupnom snagom predanom iz modula, dobije se da se za manji protok troši 1.68% predane snage, dok se za svladavanje pada tlaka većeg protoka troši 11.34% predane snage.

Na slikama 5.10 i 5.11 prikazana je distribucija brzine u modulu za različite brzine na ulazima. Mjerila su pri tome dana u različitim skalama kako bi se bolje vidjela promjena brzine unutar modula zbog velikih međusobnih razlika.

Na slikama 5.12 i 5.13 prikazana su temperaturna polja zraka u [K]. Iz slika je vidljivo da je maksimalna temperatura zraka u sredini modula, odnosno na područjima gdje je strujanje zagušeno. Također je vidljivo da je temperatura zraka na izlazima značajno manja pri većem protoku kao što pokazuju i podaci iz tablice 5.2.

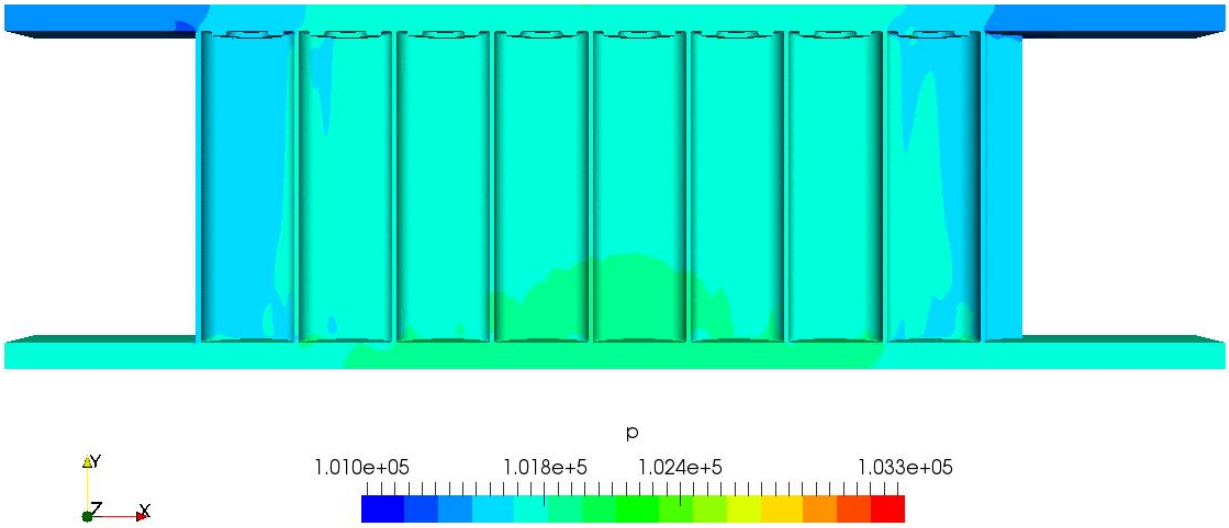

Slika 5.8 Polje tlaka [Pa] ćelija pri brzini strujanja na ulazu od 20 m/s i uniformnim razmakom između ćelija

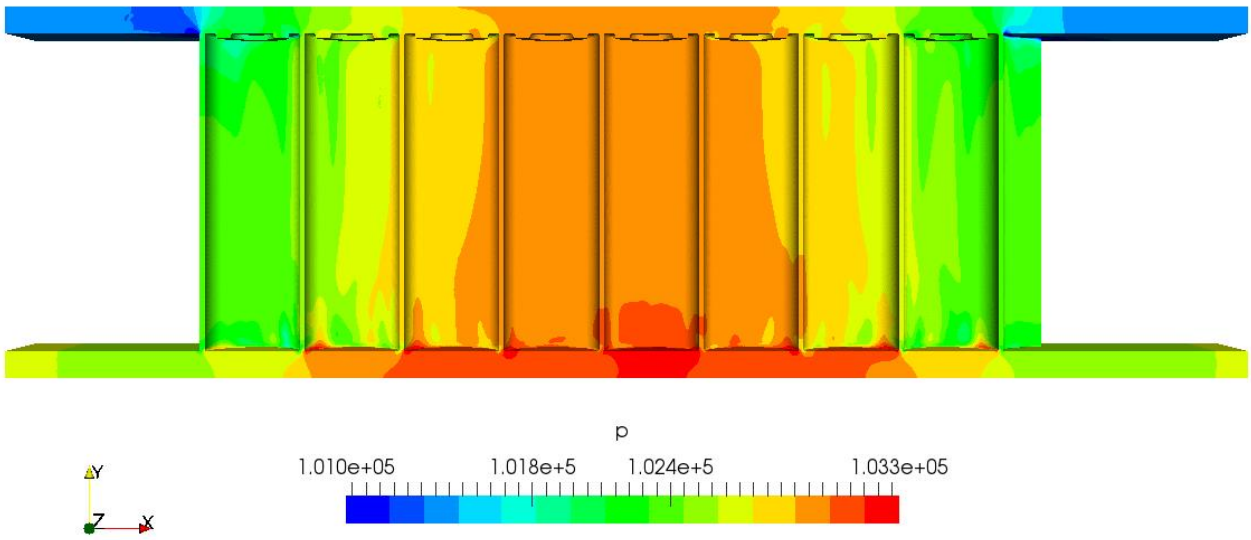

Slika 5.9 Polje tlaka [Pa] ćelija pri brzini strujanja na ulazu od 40 m/s i uniformnim razmakom između ćelija

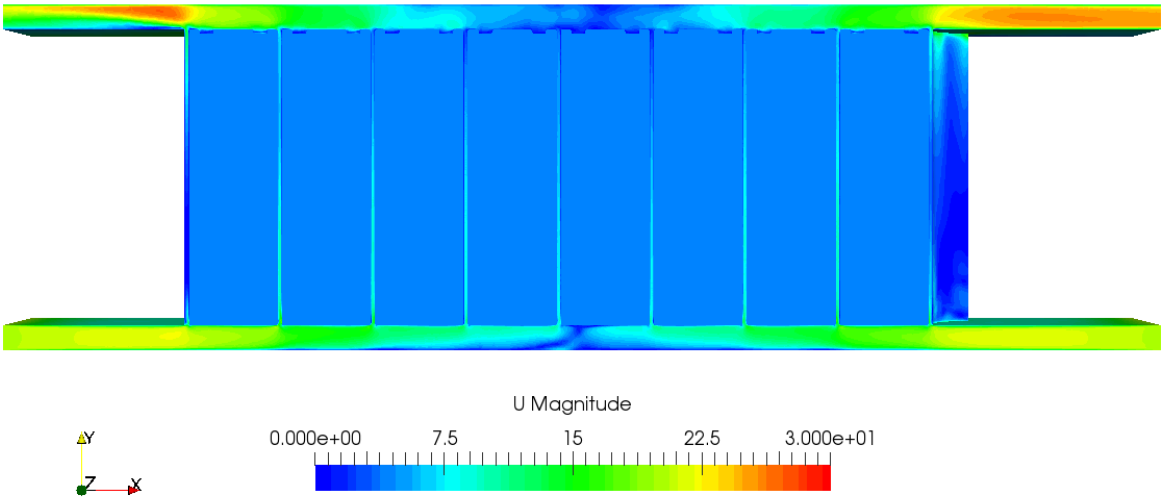

Slika 5.10 Distribucija brzine [m/s] zraka u modulu s uniformnim razmakom između ćelija i pri brzini strujanja na ulazu od 20 m/s

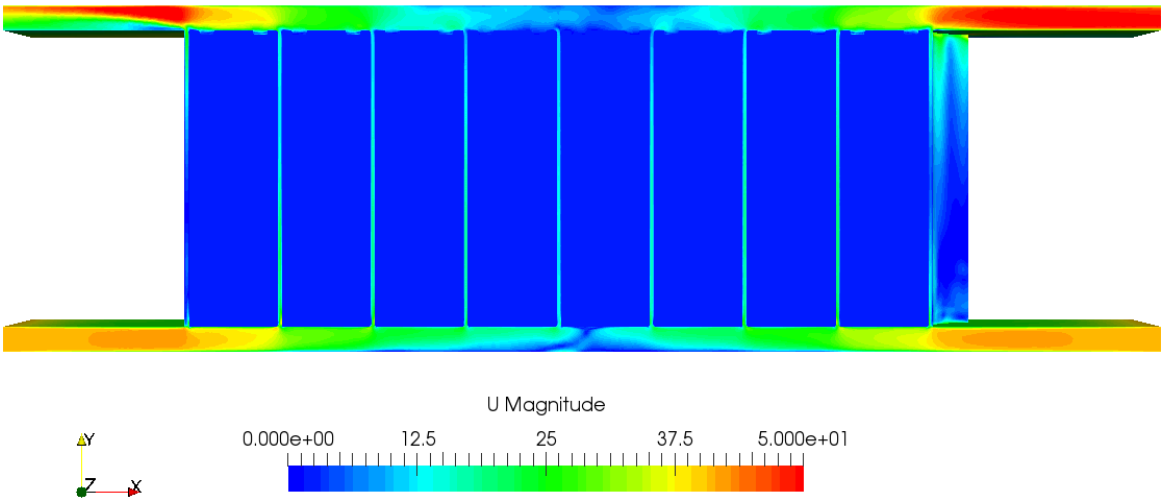

Slika 5.11 Distribucija brzine [m/s] zraka u modulu s uniformnim razmakom između ćelija i pri brzini strujanja na ulazu od 40 m/s

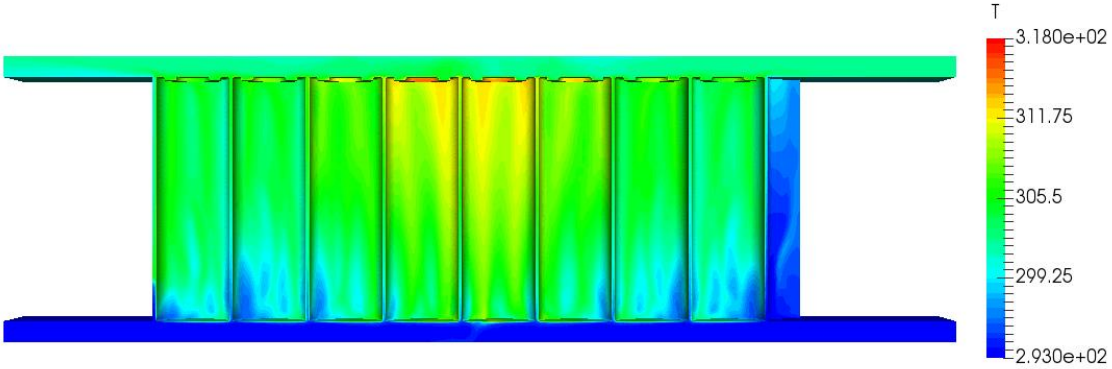

Slika 5.12 Temperaturno polje [K] zraka oko ćelija pri brzini strujanja na ulazu od 20 m/s i uniformnim razmakom između ćelija

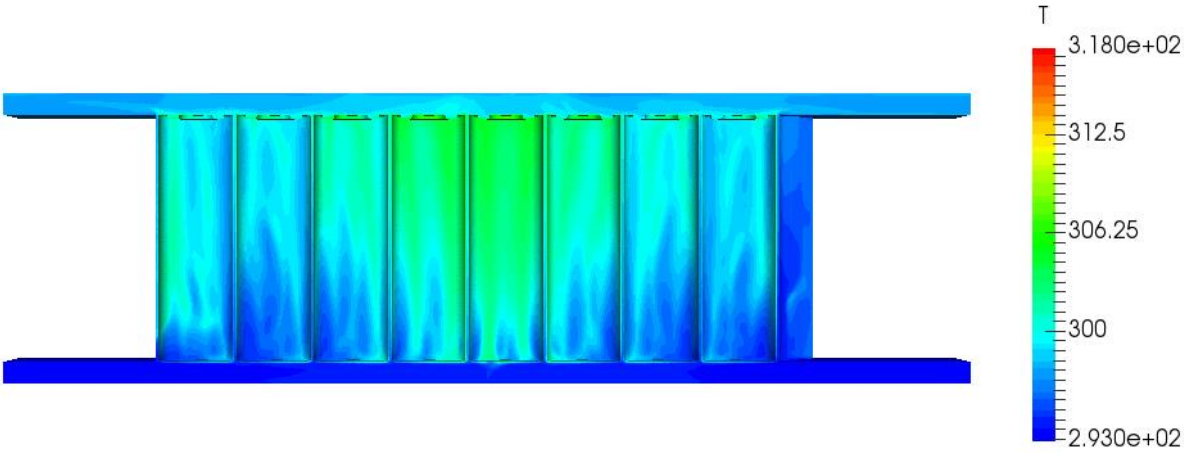

Slika 5.13 Temperaturno polje [K] zraka oko ćelija pri brzini strujanja na ulazu od 40 m/s i uniformnim razmakom između ćelija

5.2 Utjecaj uvođenja neuniformnih razmaka između ćelija na hlađenje baterijskog modula

Osim simulacija provedenih na modelu s uniformnim razmakom između ćelija, provedena je i simulacija za geometriju s neuniformnim razmakom između baterijskih ćelija ranije opisanu u poglavlju 4.3. Simulacija je provedena za protok koji odgovara ulaznoj brzini od 20 m/s te je uspoređena s modulom s uniformnim razmakom između ćelija istih početnih uvjeta. Usporedba maksimalnih i prosječnih temperatura u ćeliji te maksimalnih temperaturnih razlika unutar modula dana je u tablici 5.4.

Tablica 5.4 Temperaturno stanje ćelija pri hlađenju s uniformnim i neuniformnim razmakom između ćelija

Geometrija modula s	Maksimalna temperatura u ćeliji [°C]	Prosječna temperatura ćelije [°C]	Maksimalna razlika temperatura unutar modula [°C]
Uniformnim razmakom između ćelija	44.89	37.25	19.16
Neuniformnim razmakom između ćelija	42.67	35.66	17.42

Usporedbom rezultata prikazanih u tablici 5.3 vidljivo je da je uvođenjem neuniformnih razmaka između ćelija u modulu, pri čemu su povećani razmaci između ćelija na mjestima zagušenja protoka, maksimalna temperatura ćelija smanjena za 2.22 °C, a prosječna temperatura ćelije za 1.59 °C. Također usporedbom maksimalnih temperaturnih razlika koje se javljaju unutar modula vidljivo je da je upotrebom neuniformnih razmaka ta razlika smanjena za 1.74 °C. Preračunato u postotke dobivamo smanjenja maksimalne temperature od 4.9% , prosječne temperature ćelija od 4.3% i maksimalne temperaturne razlike unutar modula od 9.1%. Usporedbom ovih postotaka vidljivo je da je najveće poboljšanje postignuto u postizanju bolje uniformnosti hlađenja modula.

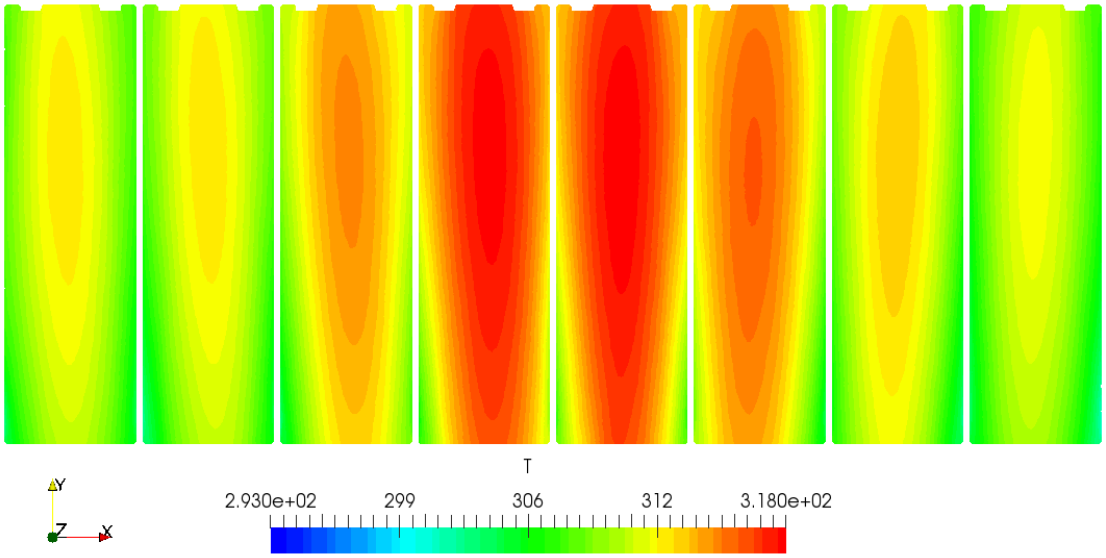

Slika 5.14 Temperaturno polje [K] ćelija pri brzini strujanja na ulazu od 20 m/s i uniformnim razmakom između ćelija

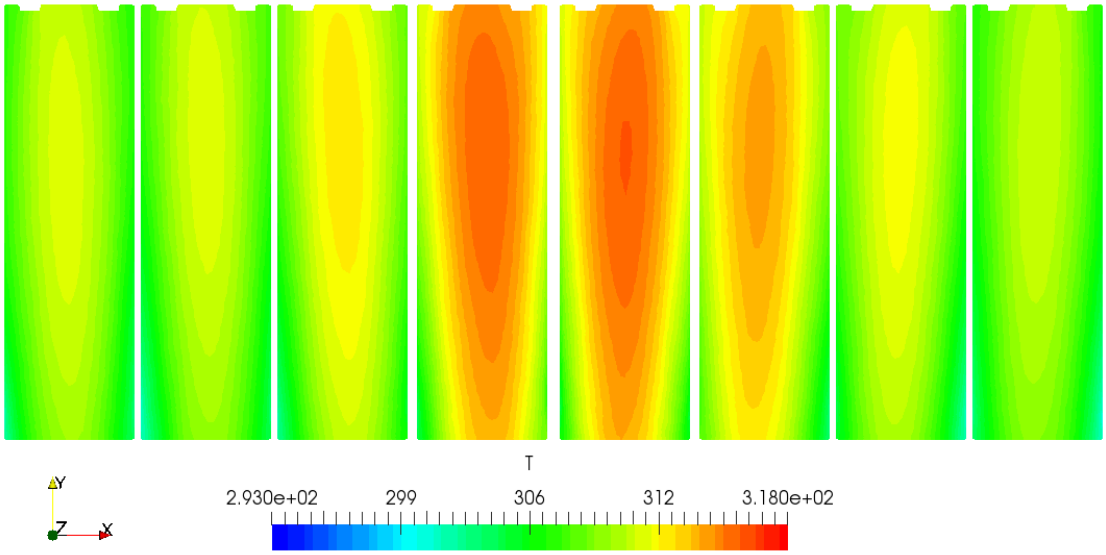

Slika 5.15 Temperaturno polje [K] ćelija pri brzini strujanja na ulazu od 20 m/s i neuniformnim razmakom između ćelija

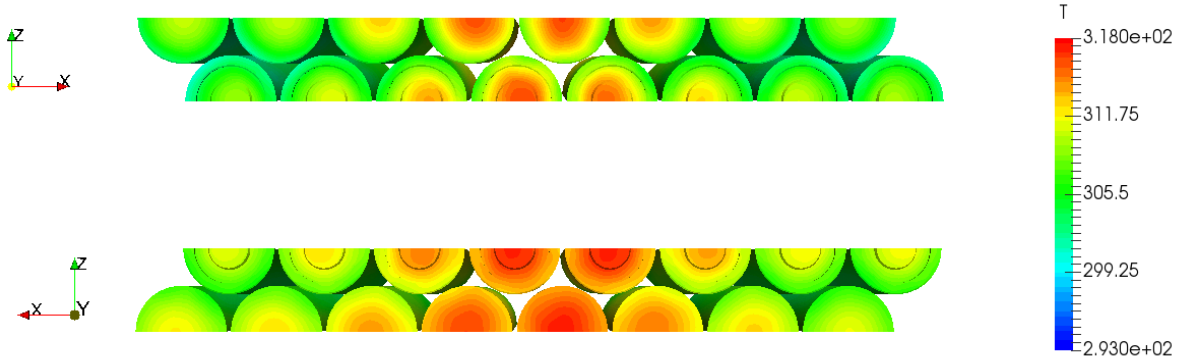

Slika 5.16 Temperaturno polje [K] ćelija pri brzini strujanja na ulazu od 20 m/s i uniformnim razmakom između ćelija –strana ćelija bliže ulazima (gornja slika) i strana ćelija bliže izlazima (donja slika)

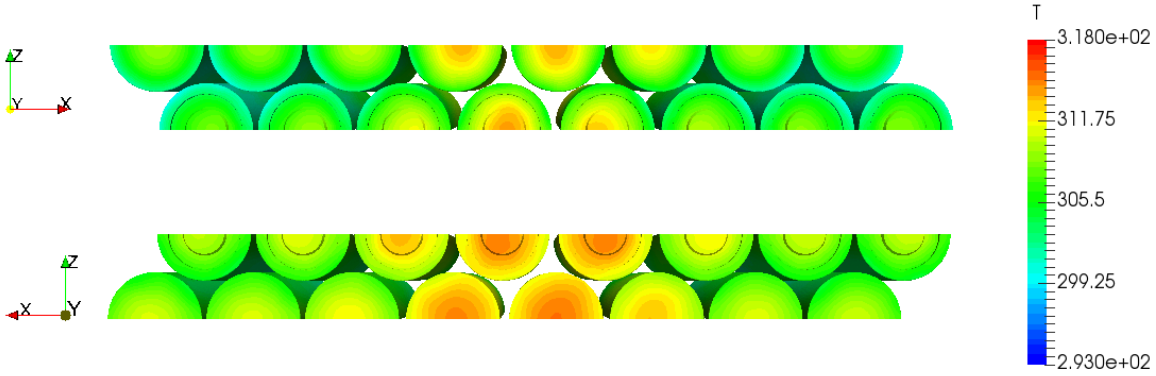

Slika 5.17 Temperaturno polje [K] ćelija pri brzini strujanja na ulazu od 20 m/s i neuniformnim razmakom između ćelija –strana ćelija bliže ulazima (gornja slika) i strana ćelija bliže izlazima (donja slika)

Na slikama 5.14 - 5.17 prikazana su temperaturna polja ćelija za ova dva slučaja pri čemu je skala dana u [K]. Iz slika je vidljivo bolje hlađenje srednjih ćelija u modulu s neuniformnim razmacima s obzirom na srednje ćelije modula s uniformnim razmakom između ćelija.

U tablici 5.5 dana je usporedba pada tlaka kroz simulirana područja i prosječnih promjena temperatura zraka na izlazima s obzirom na ulaznu temperaturu od 20 °C.

Tablica 5.5 Stanje zraka pri hlađenju s uniformnim razmakom između ćelija

Geometrija modula s	Pad tlaka [kPa] ulaz 1 – izlaz 1	Pad tlaka [kPa] ulaz 2 – izlaz 2	Prosječna promjena temperature na izlazu 1 [°C]	Prosječna promjena temperature na izlazu 2 [°C]
Uniformnim razmakom između ćelija	0.367	0.364	7.96	8.05
Neuniformnim razmakom između ćelija	0.365	0.368	7.93	7.85

Iz tablice 5.4 vidljivo je da je uvođenjem neuniformnih razmaka između ćelija u modulu pad tlaka smanjen za 2 Pa na dijelu ulaz 1 –izlaz 1 odnosno povećan za 4 Pa na dijelu ulaz 2 - izlaz 2. Prosječna promjena temperature na izlazu 1 smanjena je za 0.03 °C, a na izlazu 2 0.2 °C. Izraženo u postotcima pad tlaka smanjen je 0.5% odnosno povećan 1.1%, a razlika prosječnih promjena temperature zraka na ulazima 1 i 2 smanjena je 0.4% i 2.5%.

Na slikama 5.18 i 5.19 prikazana su polja tlaka za oba slučaja. Iz slika je vidljivo da je područje najvišeg tlaka na sredini između dva ulaza u modul, no uvođenjem većih razmaka između srednjih ćelija to je područje višeg tlaka suženo čime je strujanje u tom području olakšano. Prikaz strujanja između srednjih ćelija modula za oba slučaja dan je na slikama 5.20 i 5.21.

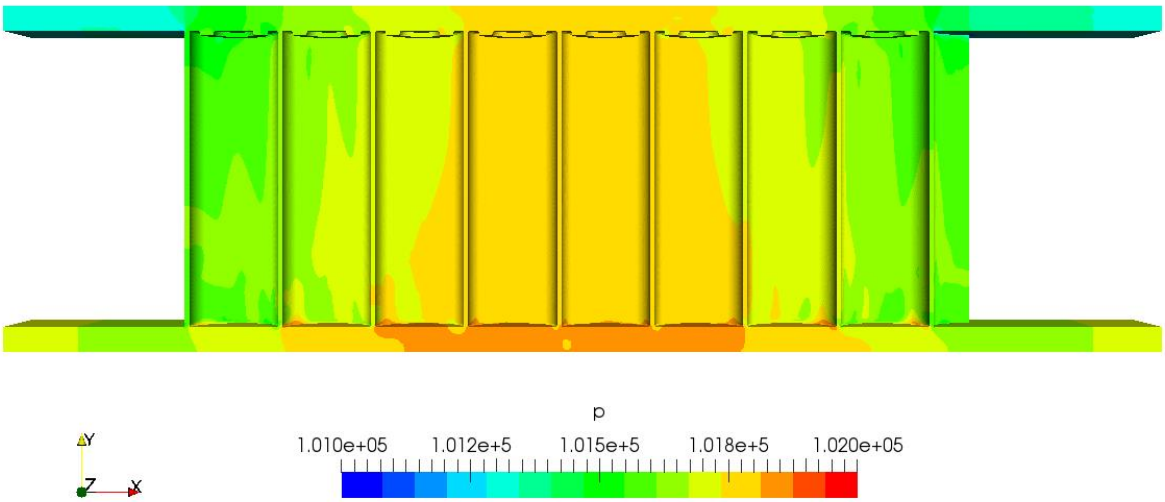

Slika 5.18 Polje tlaka [Pa] ćelija pri brzini strujanja na ulazu od 20 m/s i uniformnim razmakom između ćelija

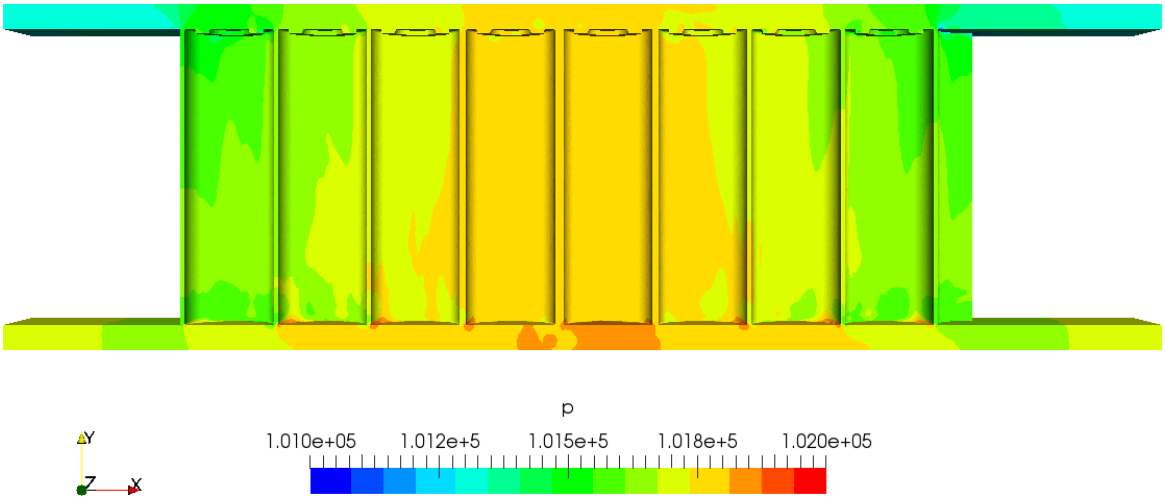

Slika 5.19 Polje tlaka [Pa] ćelija pri brzini strujanja na ulazu od 20 m/s i neuniformnim razmakom između ćelija

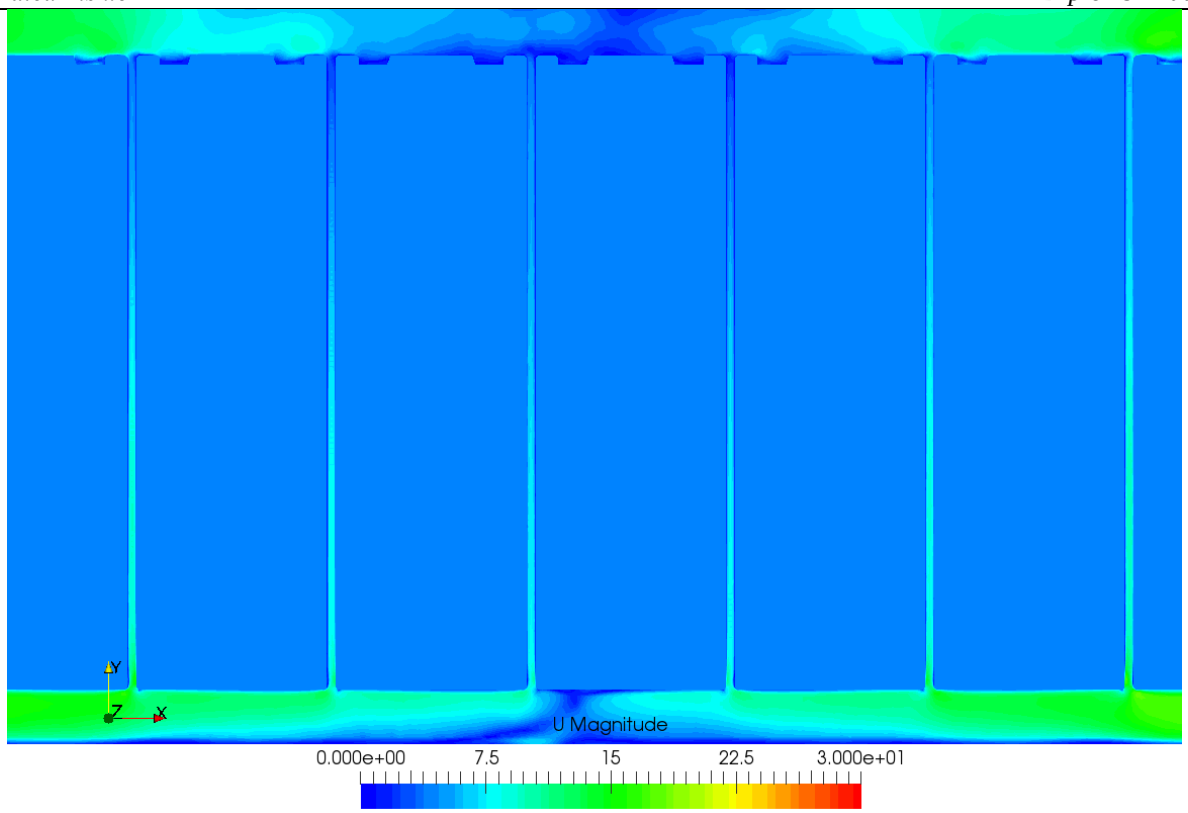

Slika 5.20 Distribucija brzine [m/s] zraka u modulu s uniformnim razmakom između ćelija i pri brzini strujanja na ulazu od 20 m/s

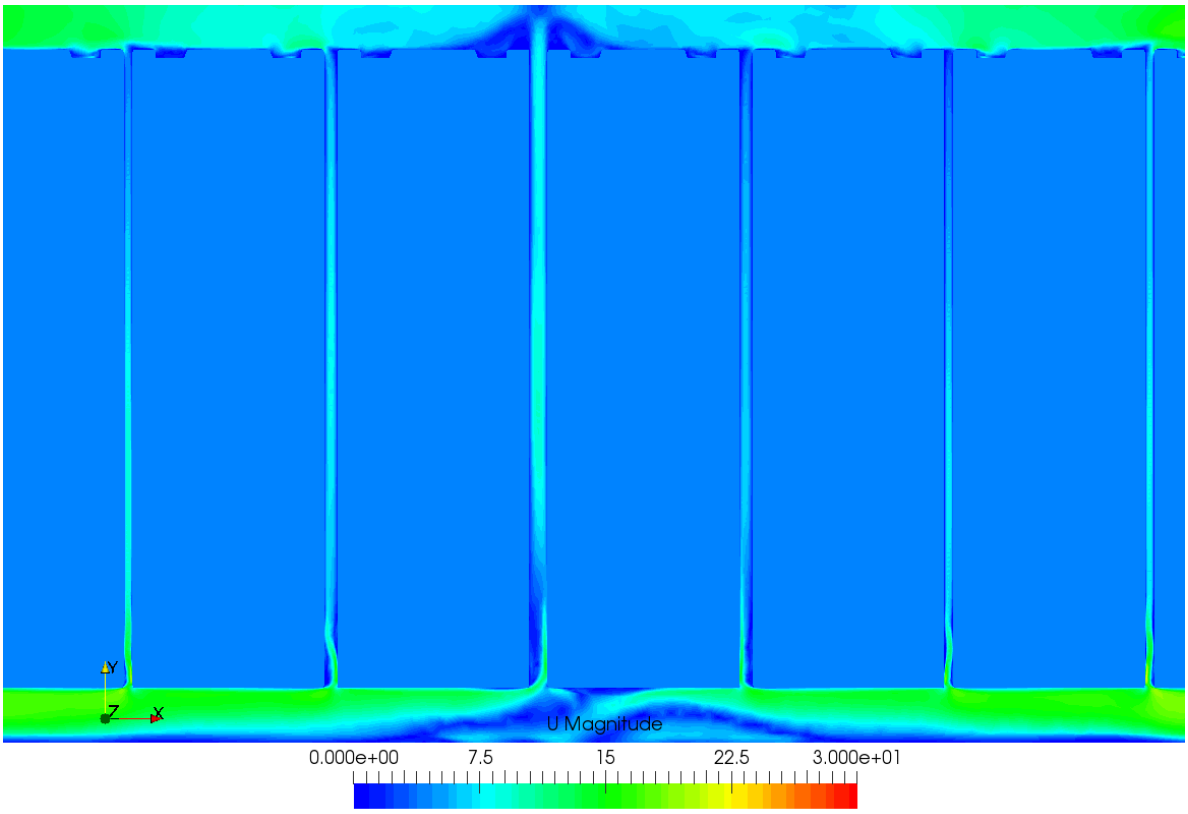

Slika 5.21 Distribucija brzine [m/s] zraka u modulu s neuniformnim razmakom između ćelija i pri brzini strujanja na ulazu od 20 m/s

Na slici 5.22 prikazano je temperaturno polje zraka u modulu s neuniformnim razmakom između ćelija. Usporedi li se temperaturno polje zraka na slici 5.22 s onime na slici 5.12 vidljivo je da se uvođenjem većeg razmaka između srednjih ćelija smanjila i maksimalna temperatura zraka na tom području koja je ujedno i maksimalna temperatura zraka u cijelom modulu.

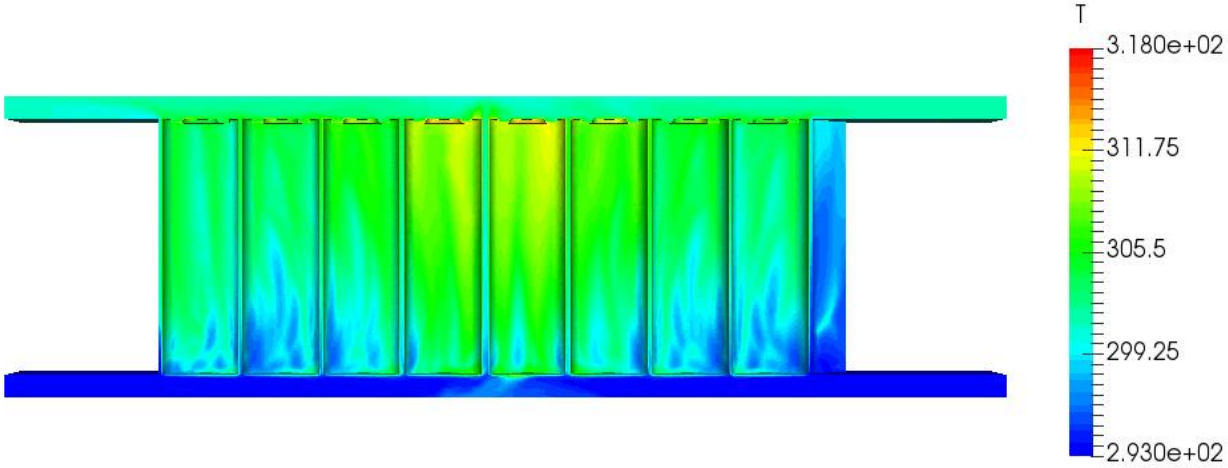

Slika 5.22 Temperaturno polje [K] zraka oko ćelija pri brzini strujanja na ulazu od 20 m/s i neuniformnim razmakom između ćelija

6. ZAKLJUČAK

U okviru ovog rada analizirano je hlađenje baterijskog modula pogonskog baterijskog paketa zrakoplova pomoću zraka. Na temelju analizirane literature te karakteristika referentnog zrakoplova i njegove baterijske ćelije, napravljene su osnovne pretpostavke potrebne za konstruiranje baterijskog modula, a na temelju tih pretpostavki zatim su napravljena 2 CAD modela. Geometrije su slične, a razlikuju se po tome što jedna ima uniforman, a druga neuniforman razmak između ćelija.

Primjenom računalne dinamike fluida temeljene na metodi kontrolnih volumena napravljena je računalna simulacija hlađenja baterijskog modula zrakom. Ukupno su provedene i analizirane tri simulacije. Dvije simulacije provedene su na geometriji s uniformnim razmakom, a pri tome je variran protok. Usporedbom rezultata te dvije simulacije, vidljivo je da je dvostrukim porastom protoka značajno smanjena maksimalna i prosječna temperatura ćelije, a u najvećem postotku poboljšana je temperaturna uniformnost ćelija unutar modula. Iako su povećanjem protoka smanjene temperature ćelija i njihove temperaturne razlike, nameće se problem značajnog povećanja pada tlaka u modulu od visokih 338%. Ovakav pad tlaka u modulu znači da je snaga (bez uračunatih gubitaka) koja se troši za njegovo svladavanje 6.76 puta veća u odnosu na duplo manji protok što izravno smanjuje energetsku učinkovitost hlađenja. Usporedbom snage potrebne za prisilnu konvekciju u modulu sa predanom snagom po modulu, vidljivo je da se za manji protok troši 1.68% predane snage, dok se za prisilnu konvekciju većeg protoka troši 11.34% predane snage. Prema tome, povećanje potrebne snage za prisilnu konvekciju značajno raste povećanjem protoka, a na štetu korisne predane snage.

Treća simulacija provedena je na geometriji s neuniformnim razmacima između ćelija, pri čemu su razmaci povećani na mjestima zagušenja strujanja zbog previsokog tlaka u odnosu na ostatak modula. Ostali parametri jednaki su parametrima strujanja u geometriji s uniformnim razmacima između ćelija i manjim protokom te su rezultati te dvije simulacije također uspoređeni. Usporedbom rezultata vidljivo je da se uvođenjem neuniformnih razmaka smanjuje maksimalna i prosječna temperatura ćelija za prosječno 4.6 % dok je temperaturna uniformnost poboljšana za nešto više od 9% uz zanemarivu promjenu pada tlaka u modulu.

Usporedimo li poboljšanje hlađenja povećanjem protoka i promjenom razmaka između ćelija dolazimo do zaključka da je znatno bolja temperaturna uniformnost postignuta

povećanjem protoka no na štetu energetske učinkovitosti takvog hlađenja dok je povećanjem razmaka između ćelija energetska učinkovitost praktično ostala ista. Daljnjim optimiranjem razmaka između ćelija njihovo bi se hlađenje moglo dodatno poboljšati.

Još je važno spomenuti kako u sve tri simulacije maksimalna temperatura ćelije ne prelazi maksimalnu dopuštenu temperaturu zadanu specifikacijama te je taj uvjet time zadovoljen, no zbog velike temperaturne neuniformnosti unutar modula životni vijek modula biti će znatno smanjen.

LITERATURA

[1] *Aircraft Batteries*, https://www.aircraftsystemstech.com/2017/06/aircraft-batteries.html, 05.11.2019.

[2] Saw, L.H., Tay A.A.O., Winston Zhang, L. : *Thermal Management of Lithium-ion Battery Pack with Liquid Cooling*, Conference: Thermal Measurement, Modeling & Management Symposium (SEMI-THERM) 298-301, 2015.

[3] Chen, K.H., Han, T., Khalighi, B., Klaus, P. : *Air Cooling Concepts for Li-ion Battery Pack in Cell Level*, ASME, Heat Transfer Summer Conference, 2017.

[4] Cho, G.Y., Choi, J.W., Park, J.H., Cha, S.W. : *Transient modeling and validation of lithium ion battery pack with air cooled thermal management system for electric vehicles*. Int. J. Automot. Technol. 15, 795–803, 2014.

[5] Fan, L., Khodadadi, J.M., Pesaran, A.A.: *A parametric study on thermal management of an air-cooled lithium-ion battery module for plug-in hybrid electric vehicles*, J. Power Sources 238, 301–312, 2013.

[6] Chen, K.,Chen, L., Chen, Y., She, Y., Song, M., Wang, S. : *Construction of effective symmetrical air-cooled system for battery thermal management*, Applied Thermal Engineering, 2019.

[7] Chen, K., Li, Z., Chen, Y., Long, S., Hou, J., Song, M., Wang, S. : *Design of Parallel Air-Cooled BatteryThermal Management System through Nuumerical Study*, Energies 10, 1677, 2017.

[8] *PCC Thermal Management*, http://www.allcelltech.com/index.php/technology/pcc-thermal-management, 21.11.2019.

[9] Han, T., Yen. C.H.E., Kalighi, B., Kaushik, S. : *Li-Ion Battery Pack Thermal Management: Liquid Versus Air Cooling*, Journal of Thermal Science and Engineering Applications, Vol. 11, 2019

[10] Virag, Z. : *Računalna dinamika fluida*, Predavanja, Fakultet strojarstva i brodogradnje, Zagreb, 2014

[11] Džijan, I. : *Doktorski rad: Numerička metoda za analizu strujanja fluida na nestrukturiranoj mreži*, Fakultet strojarstva i brodogradnje, Zagreb, 2004.

[12] Vukčević, V. : *Diplomski rad* , Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje, Zagreb, 2013.

[13] Turbulence Modeling Resource, https://turbmodels.larc.nasa.gov/sst.html 15.12.2019.

[14] *k-omega SST model*, https://www.cfd-online.com/Wiki/SST_k-omega_model, 15.12.2019.

[15] Exttra 330 Electric Aircraft, https://www.aerospace-technology.com/projects/extra-330le-electric-aircraft/ , 5.11.2019.

[16] Samsung SDI : *Specification of product – Tenative Version (TBD) for Lithium-ion rechargeable cell Model: INR21700-48G*, 2015.