Drugi simpozij o primjeni umjetne inteligencije u računalnoj mehanici

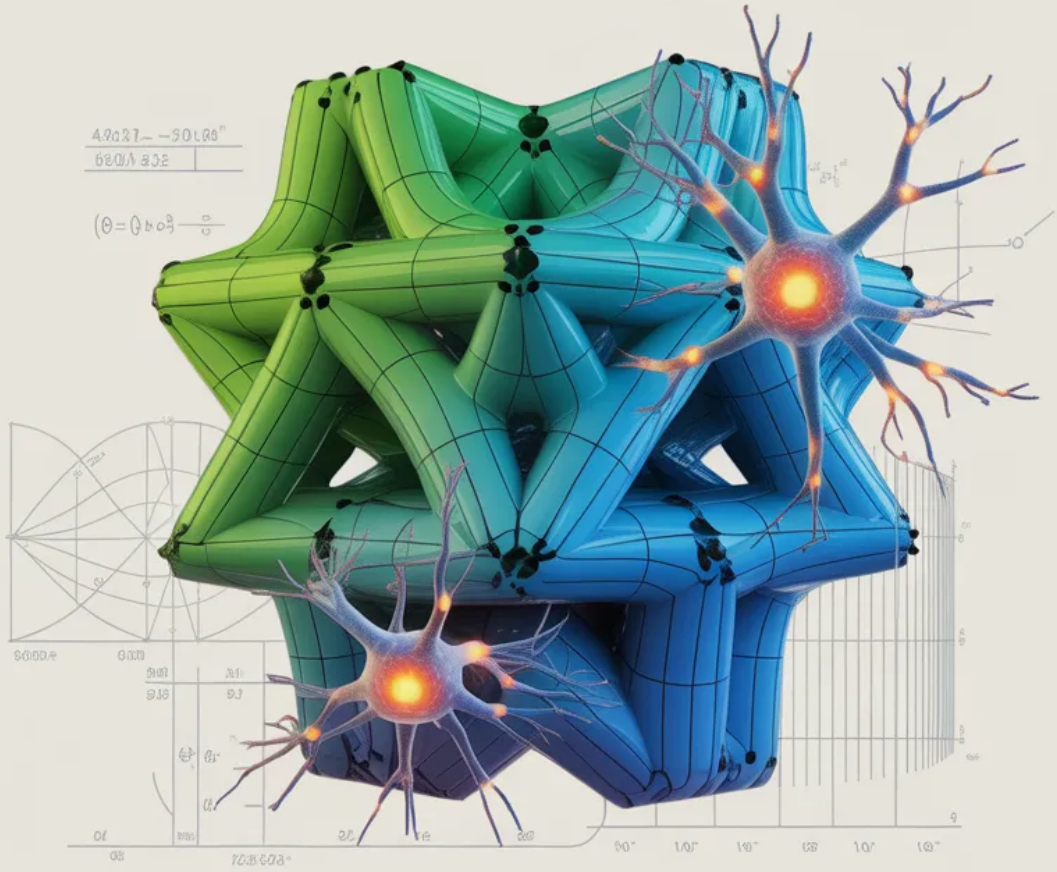

18. rujna 2026.
Dvorana Knjižnice HAZU
Strossmayerov trg 14
Zagreb

Organizatori

Hrvatska akademija znanosti i umjetnosti
Razred za tehničke znanosti

HDM
HRVATSKO DRUŠTVO ZA MEHANIKU
ZAGREB – OSIJEK – RIJEKA – SL. BROD – SPLIT

Hrvatska akademija znanosti i umjetnosti
Razred za tehničke znanosti
i
Hrvatsko društvo za mehaniku

organiziraju znanstveni skup

Drugi simpozij o primjeni umjetne inteligencije u računalnoj mehanici

u petak, 18. rujna 2026. s početkom u 10:00 sati
u Dvorani Knjižnice HAZU, Strossmayerov trg 14, Zagreb

Predsjednik simpozija
Akademik Jurica Sorić

Znanstveni i organizacijski odbor

Prof. dr. sc. Marko Čanađija, akademik Bojan Jerbić, prof. dr. sc. dr. rer. nat. Hrvoje Kozmar, akademik Ignac Lovrek, akademik Jurica Sorić, prof. dr. sc. Nikola Vladimir

Program

10:00 - 10:10 **Pozdravna riječ**
Akademik Ignac Lovrek, tajnik Razreda za tehničke znanosti
Prof. dr. sc. dr. rer. nat. Hrvoje Kozmar, predsjednik Hrvatskog društva mehaniku

Predsjedatelj: Akademik Bojan Jerbić

10:10 - 10:30 Prof. dr. sc. Luka Grubišić, Prirodoslovno-matematički fakultet, Sveučilište u Zagrebu:
Kontrola greške aproksimacije i adaptivno poboljšavanje modela u znanstvenom računanju strojnim učenjem.

10:30 - 10:50 Prof. dr. sc. Marko Čanađija, Tehnički fakultet, Sveučilište u Rijeci:
Hijerarhijske duboke neuronske mreže: Primjena na višefizičke simulacije.

10:50 - 11:10 Prof. dr. sc. Ivica Smojver, Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu:
Primjena umjetne inteligencije u konstitutivnim modelima pri analizi kompozitnih konstrukcija.

11:10 - 11:30 **Pauza za kavu**

Predsjedatelj: Prof. dr. sc. dr. rer. nat. Hrvoje Kozmar

11:30 - 11:50 Akademik Jurica Sorić, Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu:
Metode strojnog učenja u računalnoj mehanici loma.

11:50 - 12:10 Izv. prof. dr. sc. Stanko Škec, Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu:
Primjena strojnog učenja u generiranju 3D modela konstrukcija.

12:10 - 12:30 Prof. dr. sc. Željko Tuković, dr. sc. Ivan Batistić, Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu:
Fizikom vođena neuronska mreža za oblikovanje statorskih lopatica nadzvučne ORC turbine.

12:30 - 12:50 Izv. prof. dr. sc. Mijo Nikolić, Fakultet građevinarstva, arhitekture i geodezije, Sveučilište u Splitu:
Fizikalne neuronske mreže s primjenom na rješavanje stohastičkih inverznih problema.

12:50 - 13:30 **Pauza za ručak**

Predsjedatelj: Prof. dr. sc. Marko Čanađija

13:30 - 13:50 Izv. prof. dr. sc. Tomislav Lesičar, Ana Marija Šegon, Stipe Turalija, Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu:
Primjena metoda umjetne inteligencije u modeliranju heterogenih materijala.

13:50 - 14:10 Izv. prof. dr. sc. Stefan Ivić, dr. sc. Karlo Jakac, Tehnički fakultet, Sveučilište u Rijeci:
Dinamika strujanja temeljena na podacima u pomorskim operacijama traženja.

14:10 - 14:30 Prof. dr. sc. Hrvoje Gotovac, Fakultet građevinarstva, arhitekture i geodezije, Sveučilište u Splitu:
Izogeometrijski neuralni operatori u računalnoj mehanici.

14:30 - 14:50 **Pauza za kavu**

Predsjedatelj: Akademik Jurica Sorić

14:50 - 15:10 Izv. prof. dr. sc. Goranka Štimac Rončević, Tehnički fakultet, Sveučilište u Rijeci:
Primjena fizikalno informiranih neuronskih mreža u analizi vibracija greda.

15:10 - 15:30 Dr. sc. Marta Alvir, Tehnički fakultet, Sveučilište u Rijeci:
Primjena strojnog učenja za analizu podmorskih ispusta.

15:30 - 15:50 Dr. sc. Martin Zlatić, Tehnički fakultet, Sveučilište u Rijeci:
Termomehanički proširene neuronske mreže: od polikonveksnosti do konkavnosti.

15:50 - 16:20 **Rasprava i zatvaranje simpozija**

Luka Grubišić

Kontrola greške aproksimacije i adaptivno poboljšavanje modela u znanstvenom računanju strojnim učenjem

Sažetak predavanja

U ovom predavanju bavimo se konstrukcijom i validacijom modela znanstvenog strojnog učenja koji se konstruiraju iz podataka mjerenja ili rezultata visoko pouzdane (ali teško skalabilne) simulacije. Predstavljamo općeniti okvir a posteriorni pristup kontroli greške modela znanstvenog strojnog učenja (Scientific Machine Learning) primijenjenog na familije parcijalnih diferencijalnih jednadžbi koje opisuju stacionarne probleme. Cilj je izgraditi adaptivno proširive zamjenske (surogat) modele u kojima rekonstruirani rezidual trenutne aproksimacije u mjerodavnoj jednadžbi problema upravlja i profinjavanjem i verifikacijom pouzdanosti aproksimacije. Fokusiramo se na arhitekture neuronskih mreža čiji se reziduali mogu evaluirati u analitičkom obliku, bez potrebe za numeričkim ili automatskim derivanjem. Sama se metoda temelji na lokalnoj funkcijskoj reprezentaciji rekonstrukcije reziduala i na tome utemeljenom adaptivnom profinjavanju modela. Kao ogledni primjer razmatramo problem topološke optimizacije i analize naprezanja inženjerskih struktura podvrgnutih različitim konfiguracijama opterećenja i rubnih uvjeta. Numerički eksperimenti pokazuju da norma reziduala služi kao pouzdan indikator greške kroz prostornu domenu i kroz domenu parametara konstrukcije, omogućujući precizno prepoznavanje kritičnih zona i adaptivno lokalno podizanje točnosti modela.

O predavaču

Luka Grubišić je redoviti profesor u trajnom izboru Prirodoslovno matematičkog fakulteta Sveučilišta u Zagrebu. Područje njegova znanstvenog interesa je teorija operatora, numerička analiza metode konačnih elemenata, teorija aproksimacija s naglaskom na redukciju dimenzije modela te znanstveno računanje. Glavni su mu znanstveni doprinosi ostvareni u teoriji perturbacija operatora matematičke fizike, metode procjene greške aproksimacije svojstvenih funkcija i svojstvenih vrijednosti a posteriori u adaptivnim metodama konačnih elemenata, razvoju metode konturnih integrala u numeričkom rješavanju spektralnog i evolucijskog problema. Trenutno obnaša dužnost pročelnika Matematičkog odsjeka Prirodoslovno matematičkog fakulteta, predsjednika Udruge za industrijsku i primijenjenu matematiku CroMathIn te potpredsjednika Hrvatskog matematičkog društva.

Marko Čanađija

Hijerarhijske duboke neuronske mreže: Primjena na višefizičke simulacije

Sažetak predavanja

Predavanje predstavlja hijerarhijske konvolucijske neuronske mreže dubokog učenja (C-HiDeNN), primijenjene na višefizičke spregnute probleme. Kao što je to poznato, C-HiDeNN pristup postavlja metodu konačnih elemenata u okvir strojnog učenja. Umjesto klasičnih konačnih elemenata, koriste se lokalne poddomene („patch“). Unutar takvih poddomena tražene varijable interpoliraju se kombinacijom radijalnih baza i polinomskih baza, koje daju tzv. konvolucijske funkcije poddomene. Okvir strojnog učenja omogućava proširenja u vidu p-, r-, h- i a- adaptivnosti. Na početku se opisuju osnove ovakvog pristupa, a potom se daje opći okvir za višefizičke probleme. Pristup se primjenjuje na termoelastične spregnute probleme. Kao funkcija gubitka koristi se prikladan termoelastični potencijal, čijom minimizacijom slijede traženi pomaci i temperature. Posebno treba istaknuti kako se računalna implementacija temelji na JAX biblioteci u Pythonu. Ovo omogućava korištenje grafičke procesorske jedinice (GPU) i time značajno ubrzanje proračuna. Ponašanje procedure provjerava se na tri primjera: jednodimenzijski vlačni test u kojem mehanički dio problema vodi zagrijavanju

strukture, te zatim trodimenzijski problem savijanja iste prirode. Poznato je da su u slučaju spregnute analize ovi problemi vrlo loše kondicionirani i stoga zahtjevni za rješavanje. Treći primjer predstavlja slučaj problema pogonjenog termičkim pojavama, dok je mehanički odziv od sekundarnog značaja.

O predavaču

Prof. dr. sc. **Marko Čanađija** redoviti je profesor u trajnom izboru na Tehničkom fakultetu Sveučilišta u Rijeci. Aktivan je istraživač u spregnutim problemima koji uključuju i mehaniku i termodinamiku, često na nanometarskoj razini. Od 2020. godine kao osnovni alat koristi metode strojnog učenja. U časopisima indeksiranim u Web of Science (WoS) objavio je 81 članak. Objavio je i tri knjige, od kojih su dvije izdane u inozemstvu, dok je jedna objavljena u izdanju Elsevier-a. Trenutno je aktivan na međunarodnim istraživanjima s kolegama iz SAD-a, Njemačke i Italije. Vodio je 5 istraživačkih projekata. Bio je glavni organizator ili suroganizator devet domaćih i međunarodnih skupova. Mentor je na pet završenih doktorskih disertacija. Od 2023. do 2025. godine bio je na funkciji predsjednika Hrvatskog društva za mehaniku. Član je Upravnog odbora i Akademske skupštine International Centre for Mechanical Sciences (CISM), Udine, Italija, te skupštine Hrvatskog inženjerskog saveza. Član je Central European Association for Computational Mechanics (CEACM) i Gesellschaft für Angewandte Mathematik und Mechanik (GAMM). Pridruženi je urednik u dva WoS časopisa, te član uredničkih odbora u još tri WoS časopisa. Obnašao je dužnost prodekana za znanost Tehničkog fakulteta u Rijeci, a trenutno je član Savjeta za znanost i umjetnost Sveučilišta u Rijeci. Za člana suradnika Akademije tehničkih znanosti Hrvatske izabran je 2021. godine. Među nagradama izdvajaju se Nagrada Hrvatske akademije znanosti i umjetnosti za 2023. godinu, Godišnja državna nagrada za znanost za 2024. godinu, Državna nagrada za znanstvene novake u području tehničkih znanosti za 2002. godinu, te Computational Mechanics Award za 2025. godinu koju dodjeljuje Central European Association of Computational Mechanics.

Ivica Smojver

Primjena umjetne inteligencije u konstitutivnim modelima pri analizi kompozitnih konstrukcija

Sažetak predavanja

Umjetna inteligencija (UI) sve više transformira razvoj konstitutivnih modela za kompozitne konstrukcije poboljšavajući točnost, učinkovitost i prilagodljivost predviđanja ponašanja materijala. Tradicionalni konstitutivni modeli često se temelje na analitičkim formulacijama i empirijskim izrazima koji zahtijevaju eksperimentalnu kalibraciju i kompleksno opisuju nelinearno ili višerazinsko ponašanje materijala, korištenjem većeg broja parametara. Algoritmi strojnog učenja, posebno neuronske mreže, modeli dubokog učenja te modeli koji koriste velike količine podataka, mogu izravno postaviti relacije između naprezanja i deformacija ako su dostupni rezultati velikog broja numeričkih simulacija ili eksperimenata. Cilj su modeli koji pouzdano opisuju nelinearno ponašanje materijala ili mehanizme popuštanja i evolucije oštećenja bez potrebe za složenim eksplicitnim matematičkim izrazima. Definiranjem utjecaja mikrostrukturnih značajki, kao što su orijentacija vlakana, volumni udio i svojstva matrice, udio pukotina te makroskopsko mehaničko ponašanje, UI smanjuje numeričku cijenu pri vrlo detaljnim višerazinskim simulacijama koristeći metodu konačnih elemenata. Važnu primjenu predstavlja i identifikacija te kalibracija parametara koji se koriste u konstitutivnim izrazima pri čemu UI modeli učinkovito analiziraju velike skupove podataka kako bi odredili parametre modela. Konstitutivno modeliranje temeljeno na umjetnoj inteligenciji također omogućuje praćenje stanja konstrukcije u realnom vremenu, kao i upotrebu digitalnih blizanaca. Nadalje, korištenjem velikog broja podataka dobivenih senzorima u konstrukciji, modelima umjetne inteligencije moguće je predvidjeti smanjenje mehaničkih svojstava materijala i procjenu preostalog životnog vijeka izraženog kroz preostala mehanička svojstva. Uz sve ovdje

izrečeno, ključni problemi ostaju dostupnost relevantnih podataka kao i postavljanje odgovarajućih međuovisnosti parametara korištenih u različitim konstitutivnim modelima ponašanja kompozita.

O predavaču

Prof. **Ivica Smojver** djeluje na Zavodu za zrakoplovno inženjerstvo Fakulteta strojarstva i brodogradnje Sveučilišta u Zagrebu. U razdoblju od 2004. – 2018. bio je voditelj Katedre za aerodinamiku te Katedre za zrakoplovne konstrukcije. Znanstveni interesi uključuju primjenu metode konačnih elemenata u analizi kompozitnih zrakoplovnih konstrukcija; analizu ponašanja zrakoplovnih konstrukcija pri udarnim opterećenjima; primjenu višerazinskih metoda u analizi pojave oštećenja u kompozitnim konstrukcijma; numeričko modeliranje kao i samoobnavljajuće kompozitne konstrukcije. Prof. Smojver podučava predmete u području avionskih konstrukcija te mehanike kompozitnih zrakoplovnih konstrukcija na studijima zrakoplovstva i strojarstva na FSB-u, kao i predmete iz područja raketne tehnike na Sveučilišnom vojnom studiju. Imao je pozvana predavanja, među ostalim institucijama i u NASA Glenn Laboratory, Airbus, Bombardier, TsAGI (Rusija) INCAS (Rumunjska) i dr. Među ostalim članstvima, prof. Smojver je *Senior Member* u *American Institute of Aeronautics and Astronautics* (AIAA), član *European Association of Computational Mechanics,* predstavnik Hrvatske u *Programskom odboru za transport Obzora 2020 te Obzora Europe*. Obnašao je dužnost ko-predsjedatelja u *Advisory Council for Aeronautical Research and Innovation in Europe - Member States Group (ACARE – MSG)* te je bio predstavnik RH u *Clean Sky 2 States Representatives Group*. Član je *Materials Technical Committee* u *American Institute of Aeronautics and Astronautics* od 2022.

Jurica Sorić

Metode strojnog učenja u računalnoj mehanici loma

Sažetak predavanja

Za postizanje optimalnih i pouzdanih inženjerskih konstrukcija što uključuje procjenu njihova vijeka trajanja, neophodno je simuliranje nastajanja i razvoja pukotina u njihovim materijalima. U svrhu postizanja što boljih svojstava, primjenjuju se složeni materijali koji uključuju heterogenost i poroznost što naročito dolazi do izražaja na mikrorazini. Standardni numerički pristupi rješavanju problema loma temeljeni na fizikalnim zakonima poput metode konačnih elemenata najčešće su ograničeni raspoloživim računalnim resursima. Stoga se u novije vrijeme spomenute numeričke metode nastoje zamijeniti metodama strojnog učenja koje uključuju duboko učenje. Ovdje će se prikazati nova metoda dubokog učenja koja obuhvaća integraciju neuronskih mreža koje u formulaciju uključuju fizikalne relacije (Physics-Informed Neural Networks) i grafovskih neuronskih mreža (Graph Neural Networks). Na temelju trenutačne mreže predviđa se novo stanje pri čemu se koristi arhitektura koju predstavlja enkoder, procesor i dekoder, nakon čega slijedi optimizator. Između čvorova kojima su pridružene koordinate i varijable faznog polja dolazi do prijenosa poruka. Optimizator određuje funkciju gubitka pomoću koje se neuronska mreža trenira uz određivanje parametara tako da se što bolje aproksimira ciljano rješenje dobiveno metodom faznog polja. Učinkovitost postupka pokazat će se na standardnim testnim 2D primjerima, gdje se modelira nastajanje i razvoj pukotina. Osim spomenutih neuronskih mreža, prikazat će se generativni model dubokog učenja (Generative Deep Learning Model) za predviđanje širenja pukotina u poroznim materijalima na temelju slika njihovih mikrostruktura. Pritom će se razmatrati generativne suparničke mreže (Generative Adversarial Networks).

O predavaču

Jurica Sorić je professor emeritus na Fakultetu strojarstva i brodogradnje Sveučilišta u Zagrebu, redoviti je član Hrvatske akademije znanosti i umjetnosti i Akademije tehničkih znanosti Hrvatske Bio je voditelj Katedre za mehaniku i čvrstoću. Kao gostujući istraživač i gostujući profesor, u više

je navrata boravio na inozemnim sveučilištima: Sveučilište Ruhr u Bochumu, Tehničko sveučilište u Beču, Sveučilište Karlsruhe i University of California, Irvine, SAD. Dobitnik je prestižnih stipendija zaklada Alexander von Humboldt i Fulbright. U okviru zajedničkih projekata boravio je i provodio istraživanja na Tehničkom sveučilištu u Darmstadtu i na Sveučilištu u Hannoveru. Njegova znanstvena djelatnost odnosi se na razvoj numeričkih algoritama u metodi konačnih elemenata za linearnu i nelinearnu analizu čvrstoće i stabilnosti ljuskastih konstrukcija, na razvoj bezmrežnih metoda te na proučavanje algoritama temeljenih na strojnom učenju. Objavio je 296 znanstvenih radova, od kojih su 74 u znanstvenim časopisima. Dobio je međunarodne nagrade CEACM Prof. Mang Award, i ICCES Distinguished Fellow, SAD. Domaće nagrade su: Velika medalja Fakulteta strojarstva i brodogradnje Sveučilišta u Zagrebu, Nagrada Sveučilišta u Zagrebu Fran Bošnjaković, Nagrada Hrvatske akademije znanosti i umjetnosti, Nagrada Josip Juraj Strossmayer te Državna nagrada za znanost. Član je Uređivačkog odbora časopisa CMES i Transactions of FAMENA. Bio je član organizacijskog ili znanstvenog odbora više od 50 međunarodnih konferencija. Recenzent je više od 50 radova u međunarodnim časopisima. Član je Znanstvenog vijeća Međunarodnog centra za mehaničke znanosti, CISM Udine. Član je CEACM-a, a bio je član Znanstvenog odbora i predsjednik od 2005. do 2008. Bio je član Općeg vijeća IACM-a. Od domaćih znanstvenih udruga, počasni je član Hrvatskog društva za mehaniku, a bio je predsjednik od 2007. do 2009. Član je Upravnog odbora Kluba hrvatskih humboldtovaca.

Stanko Škec

Primjena strojnog učenja u generiranju 3D modela konstrukcija

Sažetak predavanja

Implicitni pristup generativnom konstruiranju, koji je glavni fokus ovog istraživanja, temelji se na primjeni modela strojnog učenja, poput generativnih suparničkih mreža, varijacijskih autoenkodera i difuzijskih modela. Takvi se modeli koriste za učenje geometrijskih obrazaca iz postojećih skupova 3D modela te za generiranje novih geometrijskih varijanti. Ovo se istraživanje nadovezuje na prethodno razvijen istraživački okvir u kojem su obrađeni industrijski skupovi STL podataka, izrađeni sintetički skupovi podataka iz parametarskih CAD modela primjenom alata Rhino3D i Grasshopper te provedena karakterizacija geometrijske varijabilnosti. Kao geometrijska reprezentacija koristi se oblak točaka, koji omogućuje fleksibilan opis složenih 3D geometrija nakon pretvorbe iz različitih CAD i STL formata. Budući da oblak točaka ne sadržava eksplicitne informacije o topologiji ni povezanosti elemenata, potrebno je obuhvatiti i postupke njegove rekonstrukcije u mrežne ili druge reprezentacije prikladne za inženjersku primjenu. Cilj je istraživanja proširiti pristup generiranju i modifikaciji novih varijanti uvođenjem dodatnih ulaznih uvjeta za manipulaciju ishoda naučenih geometrijskih obrazaca. U početnim su eksperimentima ispitane metode dovršavanja oblaka točaka temeljene na transformatorskoj arhitekturi, poput metode PoinTr, kao i difuzijske metode za generiranje 3D oblaka točaka (npr. PDR – Point Diffusion Refinement, reverzni difuzijski proces). Odabir metode PoinTr omogućuje korištenje djelomične ili nepotpune geometrije kao ulaza te generiranje nedostajućih dijelova oblika, što je važno za buduće kontrolirano generiranje novih geometrijskih varijanti. S druge strane, difuzijske metode omogućuju stabilno probabilističko učenje složenih geometrijskih distribucija iterativnim uklanjanjem šuma te ublažavaju određene nedostatke alternativnih pristupa, poput nestabilnog treniranja ili pretjeranog zaglađivanja geometrije. Međutim, ispitane generativne metode zasad ne omogućuju dovoljno izravnu kontrolu dimenzijskih parametara, što je ključno za generiranje tehnički valjanih geometrijskih varijanti. Stoga se istraživanje usmjerava prema metodama dovršavanja oblaka točaka i uvjetovanoga generiranja, pri čemu se djelomična geometrija, granične krivulje, dimenzijska ograničenja ili funkcionalne regije mogu koristiti kao ulazni uvjeti za stvaranje valjanih i kontroliranih varijanti. Razvoj takvog pristupa važan je iz dvaju glavnih razloga. Prvo, uvođenjem sintetičkih skupova podataka omogućuje se povezivanje geometrijskih varijanti s parametrima modela i oznakama segmenata, čime se stvara osnova za

integraciju dodatnih izvora podataka, uključujući rezultate numeričkih simulacija. Drugo, uključivanje rezultata metoda konačnih elemenata moglo bi omogućiti razvoj uvjetovanih generativnih metoda koje, uz geometrijska ograničenja, uzimaju u obzir i kriterije mehaničke izvedbe. Time se otvara mogućnost razvoja mehanički informiranog generiranja i validacije novih konstrukcijskih varijanti.

O predavaču

Stanko Škec izvanredni je profesor na Fakultetu strojarstva i brodogradnje Sveučilišta u Zagrebu, na Katedri za konstruiranje i razvoj proizvoda pri Zavodu za konstruiranje. Bio je gostujući profesor na Danskom tehničkom sveučilištu Danske, gdje je dodatno razvijao svoj istraživački rad u području računalno potpomognutog konstruiranja i razvoja proizvoda. Glavni dio njegova istraživanja usmjeren je na razvoj i primjenu naprednih računalnih metoda u konstruiranju i analizi inženjerskih sustava. Poseban naglasak stavlja na povezivanje generativnog konstruiranja, računalnih simulacija, metoda umjetne inteligencije i eksperimentalne validacije.

Željko Tuković, Ivan Batistić

Fizikom vođena neuronska mreža za oblikovanje statorskih lopatica nadzvučne ORC turbine

Sažetak predavanja

Iskorištavanje otpadne topline niske i srednje temperature primjenom organskih Rankine-ovih ciklusa (ORC) važno je za poboljšanje učinkovitosti i održivosti industrijskih i energetskih sustava. U kompaktnim ORC turboekspanderima visoka specifična snaga i veliki omjeri tlakova često zahtijevaju jednostupanjske ili dvostupanjske izvedbe turbina koje rade u transoničnim ili nadzvučnim režimima strujanja. U takvim je uvjetima projektiranje statorskih lopatica otežano zbog utjecaja stlačivosti fluida te realnog termodinamičkog ponašanjanja organskih fluida. Konvencionalne metode projektiranja nadzvučnih statorskih lopatica, poput metode karakteristika, uglavnom su primjenjive na divergentni tj. nadzvučni dio međulopatičnih kanala, dok se konvergentno područje najčešće definira empirijskim ili heurističkim postupcima. U ovom je radu predložena inverzna metoda projektiranja nadzvučnih statorskih lopatica turbina zasnovana na fizikom vođenim neuronskim mrežama (PINN). Predloženi postupak generira cjelokupni međulopatični kanal, uključujući i konvergentno i divergentno područje, polazeći od zadane geometrije srednje linije i raspodjele Machova broja. Polje brzine se dobiva rješavanjem jednadžbi koje opisuju stacionarno, neviskozno, adijabatsko, bezvrtložno strujanja realnog plina primjenom PINN-a. Strategija strogog nametanja rubnih uvjeta koristi se za točno zadavanje propisane raspodjele brzine duž srednje linije, dok se realni termodinamički učinci fluida uključuju putem tablica za brzinu zvuka i gustoću. Konture lopatica se zatim rekonstruiraju iz izo-linija strujne funkcije. Metoda je testirana na dva radna fluida: zrak, tretiran kao savršeni plin, i toluen pri transkritičnoj ekspanziji. Dobiveni međulopatični kanali najprije su provjereni CFD simulacijama strujanja neviskoznog stlačivog fluida, koje pokazuju dobro slaganje između propisanih i izračunanih raspodjela Machova broja duž srednje linije. CFD simulacije turbulentnog strujanja stlačivog fluida kroz odgovarajuću dvodimenzijsku rešetku lopatica potvrđuju glatko ubrzanje toka kroz međulopatični kanal, bez pojave udarnih valova i uz samo slabe kose udarne valove nizvodno od izlaznog brida. Za oba fluida omjer naknadne ekspanzije približno je jednak jedinici, a izlazni kut strujanja blizak je propisanom geometrijskom kutu lopatice. Rezultati pokazuju da predložena inverzna metoda projektiranja zasnovana na PINN-u pruža sustavan i fizikalno dosljedan pristup generiranju profila nadzvučnih statorskih lopatica plinskih turbina koje rade s idealnim ili realnim plinom.

O predavačima

Željko Tuković je redoviti profesor u Zavodu za energetska postrojenja, energetiku i okoliš na Fakultetu strojarstva i brodogradnje Sveučilišta u Zagrebu. Provodi istraživanja u području primjene

metode kontrolnih volumena u numeričkom rješavanju problema mehanike kontinuuma. Posebice je fokusiran na sljedeća područja: interakcija između fluida i krutog tijela, numeričko modeliranje višefaznog strujanja primjenom pomičnih mreža, primjena numeričkih metoda u konstrukciji turbostrojeva. Sudjelovao je u nizu domaćih i međunarodnih istraživačkih projekta te je objavio 44 recenzirana rada u međunarodnim časopisima (https://www.researchgate.net/profile/Zeljko-Tukovic).

Ivan Batistić viši je asistent na Fakultetu strojarstva i brodogradnje Sveučilišta u Zagrebu, pri Zavodu za mehaniku fluida, gdje je voditelj Laboratorija za računalnu dinamiku fluida. Njegov znanstveni i stručni rad usmjeren je na računalnu dinamiku fluida, metodu kontrolnih volumena te razvoj numeričkih metoda za simulacije fluida, deformabilnih tijela i njihove međusobne interakcije. Drži nastavu iz područja mehanike fluida i računalne dinamike fluida te sudjeluje u znanstveno-istraživačkim projektima. Dobitnik je Nagrade za mladog znanstvenika Hrvatskog društva za mehaniku. Popis znanstvenih radova dostupan je na njegovom ResearchGate profilu.

Mijo Nikolić

Fizikalne neuronske mreže s primjenom na rješavanje stohastičkih inverznih problema

Sažetak predavanja

Razvoj metoda umjetne inteligencije posljednjih je godina značajno unaprijedio mogućnosti modeliranja i predviđanja ponašanja složenih inženjerskih sustava. Najčešći pristupi strojnog učenja u pravilu zahtijevaju velike količine podataka za treniranje te velik broj numeričkih simulacija, što često predstavlja ograničenje u području mehanike materijala i konstrukcija. Fizikalne neuronske mreže (Physics-Informed Neural Networks – PINN) predstavljaju novi pristup u kojem se proces učenja ne temelji isključivo na eksperimentalnim ili numeričkim podacima, već i na fizikalnim zakonima opisanim diferencijalnim jednadžbama. U ovom predavanju prikazuje se potencijal fizikalnih neuronskih mreža za rješavanje stohastičkih inverznih problema u mehanici. Modeli koriste metodu kolokacije pri kojoj se unutar promatrane domene generira skup kolokacijskih točaka. U tim se točkama provjerava zadovoljavanje diferencijalnih jednadžbi, rubnih i početnih uvjeta. Predavanje istražuje primjenu fizikalnih neuronskih mreža na identifikaciju parametara materijala i konstrukcija te procjenu stanja građevinskih elemenata i sustava. Prikazat će se mogućnosti integracije probabilističkih metoda temeljenih na Bayesovom pristupu kvantifikacije nesigurnosti i rješavanja stohastičkih inverznih problema. Iako je treniranje fizikalnih neuronskih mreža u deterministčkim problemima često računalno zahtjevnije od klasičnih numeričkih metoda, njihov potencijal dolazi do izražaja u inverznim problemima gdje se mogu razviti parametarski modeli i neuralni operatori sposobni za brzu identifikaciju parametara i propagaciju nesigurnosti. Predavanje će prikazati aktualna istraživanja i primjenu fizikalno utemeljenog strojnog učenja u građevinarstvu i računalnoj mehanici

O predavaču

Mijo Nikolić je rođen u Splitu 02. siječnja 1988. godine. Nakon završenog sveučilišnog diplomskog studija građevinarstva na Fakultetu građevinarstva, arhitekture i geodezije Sveučilišta u Splitu, upisao je dvojni doktorski studij između École Normale Supérieure de Cachan u Parizu u Francuskoj i Fakulteta građevinarstva, arhitekture i geodezije Split. Doktorski rad je obranio 2015. godine. Trenutno radi kao izvanredni profesor na Katedri za tehničku mehaniku Fakultetu građevinarstva, arhitekture i geodezije Sveučilišta u Splitu. Njegova znanstveno-istraživačka djelatnost odvija se u području teorijske i računalne mehanike, razvoju fizikalnih i numeričkih modela s primjenom u geotehnici, konstrukcijama i materijalima, rješavanju inverznih problema, stohastičkih proračuna, teorije Bayesove uvjetne vjerojatnosti u primjeni na identifikaciju parametara te primjeni umjetne inteligencije, strojnog učenja i modela temeljenih na velikoj količini podataka. Trenutno se bavi

razvojem fizikalnih neuronskih mreža i njihovom primjenom u rješavanju inverznih i stohastičkih problema u građevinskim konstrukcijama i konstruktivnim elementima

---

Tomislav Lesičar, Ana Marija Šegon, Stipe Turalija

Primjena metoda umjetne inteligencije u modeliranju heterogenih materijala.

Sažetak predavanja

Opis mehaničkog ponašanja materijala tradicionalno se temelji na analitičkim izrazima koji proizlaze iz opsežnih eksperimentalnih ispitivanja. S obzirom na rastuću potrebu za razvojem novih materijala složene mikrostrukture, kao i na sve intenzivniju ponovnu uporabu postojećih materijala, nužno je primijeniti napredne i učinkovitije metode za opis konstitutivnog ponašanja. Metode strojnog učenja temeljene na neuronskim mrežama posljednjih su godina postale važan alat u modeliranju materijala. U tom kontekstu, unaprijedne (feedforward) neuronske mreže uspješno se primjenjuju za opis nelinearnih konstitutivnih zakona, opisivanjem ponašanja plohe tečenja. Uz njih, sve veću pažnju privlače i transformer neuronske mreže, koje zahvaljujući mehanizmu pažnje (attention) omogućuju učinkovitije učenje složenih konstitutivnih zakona. Paralelno s tim, sve je izraženiji fokus na pouzdanu procjenu cjelovitosti konstrukcija i produljenje njihova životnog vijeka, uz razvoj izdržljivih, laganih, ekonomičnih i ekološki prihvatljivih konstrukcijskih rješenja. Primjena numeričkih simulacija i naprednih metoda, poput metode faznog polja, omogućuje procjenu oštećenja postojećih konstrukcija te optimiranje i razvoj novih sustava poboljšanih performansi već u fazi projektiranja. U ovom predavanju bit će prikazana primjena unaprijedne neuronske mreže za opis plohe tečenja kod elastoplastičnog ponašanja materijala te transformer arhitekture za modeliranje nelinearnog konstitutivnog ponašanja materijala. Materijalni model pogonjen neuronskom mrežom kombiniran je s jednadžbama faznog polja te ugrađen u metodu konačnih elemenata u obliku razdvojenog algoritma rješavanja sustava diferencijalnih jednadžbi za modeliranje oštećenja u materijalima i procjenu cjelovitosti konstrukcija. Učinkovitost metode demonstrirana je na jednostavnim akademskim primjerima iz literature.

O predavačima

Izv. prof. dr. sc. **Tomislav Lesičar** zaposlen je u Zavodu za tehničku mehaniku Fakulteta strojarstva i brodogradnje Sveučilišta u Zagrebu, gdje drži nastavu iz područja čvrstoće materijala i numeričkih metoda u mehanici čvrstih tijela. Njegovo područje istraživanja obuhvaća napredne numeričke metode za analizu procesa deformiranja mehaničkih konstrukcija, napredne formulacije metode konačnih elemenata, razvoj algoritama za numeričko modeliranje oštećenja i zamora te višerazinsko modeliranje materijala uključujući razmatranja na mikrorazini. Izvanredni profesor Lesičar je kao suradnik sudjelovao na 4 znanstveno-istraživačka međunarodna projekta, 2 domaća istraživačka projekta i 2 istraživačko-razvojna projekta u suradnji s gospodarstvom. Trenutno je voditelj institucijskog istraživačkog projekta „Integrirani eksperimentalno-numerički pristup modeliranju gubitka nosivosti konstrukcijskih komponenata proizvedenih aditivnim tehnologijama (INTEKSPRO)“. Objavio je više od 90 znanstvenih radova. 17 radova je indeksirano u citatnoj bazi WoSCC, 14 radova se nalazi u časopisima koji su u bazi *Current Contents (*CC*)*, od čega je 8 radova objavljeno u 25 % najbolje rangiranih časopisa u predmetnom području, odnosno pripadaju kvartilu Q1. 2 rada se nalaze u 5% najboljih časopisa. Prezentirao je više od 20 radova na međunarodnim konferencijama. Prema citatnoj bazi *Web of Science*, citiran je u 258 bibliografskih jedinica, a prema *Scopus* 293 bibliografske jedinice. Trenutno je mentor 4 doktorske disertacije u izradi, dok je jedna doktorska disertacija pod njegovim mentorstvom uspješno obranjena.

Ana Marija Šegon, mag. ing. mech., zaposlena je kao asistentica u Zavodu za tehničku mehaniku Fakulteta strojarstva i brodogradnje Sveučilišta u Zagrebu. Doktorandica je na studiju strojarstva, smjer numerička mehanika, pod mentorstvom izv. prof. dr. sc. Tomislava Lesičara. Njezino područje

istraživanja obuhvaća razvoj naprednih numeričkih metoda za opisivanje ponašanja materijala, s posebnim naglaskom na primjenu metoda strojnoga učenja i neuronskim mreža za konstitutivno modeliranje heterogenih materijala. Njezina istraživanja obuhvaćaju metodu konačnih elemenata, višerazinsko modeliranje, konstitutivne modele temeljenje na neuronskim mrežama te modeliranje oštećenja i loma materijala. Kao suradnica sudjeluje na 1 institucijsko-istraživačkom projektu. Prezentirala je 2 rada na međunarodnim i domaćim konferencijama. Kao asistentica sudjeluje u izvođenju vježbi iz područja numeričkih metoda u mehanici čvrstih tijela i metodi konačnih elemenata.

Stipe Turalija, univ. mag. ing. mech., zaposlen je kao asistent u Zavodu za tehničku mehaniku Fakulteta strojarstva i brodogradnje Sveučilišta u Zagrebu. Doktorand je na studiju strojarstva, a njegov je studijski savjetnik izv. prof. dr. sc. Tomislav Lesičar. Njegovo istraživanje usmjereno je na modeliranje konstitutivnog ponašanja i oštećenja heterogenih materijala primjenom neuronskih mreža. Područje njegova istraživanja obuhvaća metodu konačnih elemenata, nelinearnu mehaniku čvrstih tijela, razvoj numeričkih algoritama, modeliranje oštećenja i loma te primjenu strojnog učenja u računalnoj mehanici. U nastavnom radu sudjeluje u izvođenju vježbi iz područja mehanike čvrstih tijela i metode konačnih elemenata.

Stefan Ivić, Karlo Jakac

Dinamika strujanja temeljena na podacima u pomorskim operacijama traženja

Sažetak predavanja

Predavanje obrađuje kritični problem lociranja objekata ili unesrećenih osoba na moru, gdje morske struje i vjetrovi neprekidno mijenjaju dinamiku okruženja. Ključni doprinos istraživanja leži u razvoju i primjeni tzv. "flow-fit" okvira – inovativnog pristupa rekonstrukciji površinskih strujanja u realnom vremenu na temelju oskudnih i raspršenih mjerenja koristeći surogat model strujanja. Umjesto oslanjanja isključivo na kompleksne i računalno zahtjevne standardne simulacije dinamike fluida (CFD), ovaj model koristi podatke prikupljene s terena za brzu i preciznu aproksimaciju strujanja u submezoskalnim domenama, što omogućuje točno predviđanje advekcije (gibanja) objekata ili zagađenja na površini mora. U drugom dijelu, predavanje prikazuje kako se dobiveni podaci o strujanju integriraju s naprednim algoritmima za upravljanje više-robotskim sustavima. Upravljanje pretraživanjem je HEDAC metoda (Heat Equation Driven Area Coverage), tj. algoritam ergodičke kontrole koji omogućuje autonomnim bespilotnim letjelicama da inteligentno i koordinirano pretražuju dinamička morska područja, automatski se prilagođavajući nesigurnostima u podacima, minimizirajući redundanciju i maksimizirajući vjerojatnost pronalaska cilja u najkraćem mogućem roku. Kroz predavanje će biti prikazani teorijski modeli, numerički rezultati (FEM i CFD analize), kao i konkretna iskustva i podaci prikupljeni tijekom stvarnih terenskih ispitivanja u Jadranskom moru (poput Valunskog zaljeva), čime se premošćuje jaz između fundamentalne dinamike fluida, strojnog učenja i praktične primjene u civilnim sigurnosnim operacijama.

O predavačima

Stefan Ivić diplomirao je strojarstvo 2008. godine, a doktorirao u području tehničkih znanosti 2014. godine na Sveučilištu u Rijeci. Od 2008. godine zaposlen je na Tehničkom fakultetu Sveučilišta u Rijeci, gdje je trenutačno u zvanju redovnog profesora na Zavodu za mehaniku fluida i računarsko inženjerstvo. Voditelj je projekta Hrvatske zaklade za znanost "Autonomni sustav bespilotnih letjelica za traganje i spašavanje na moru" i "Diffusion-based Ergodic Coverage for Robotics". Njegovi istraživački interesi obuhvaćaju razvoj optimizacijskih metoda i njihovu primjenu na inženjerske probleme temeljene na numeričkim simulacijama, kao i ergodičko upravljanje te autonomne sustave bespilotnih letjelica.

Karlo Jakac diplomirao je strojarstvo 2021. godine, a doktorirao u području tehničkih znanosti 2025. godine na Tehničkom fakultetu Sveučilišta u Rijeci. Od 2021. godine zaposlen je na Tehničkom fakultetu Sveučilišta u Rijeci, gdje trenutačno radi kao poslijedoktorand na Zavodu za mehaniku fluida i računarsko inženjerstvo. Član je projekata Hrvatske zaklade za znanost „Autonomni sustav bespilotnih letjelica za traganje i spašavanje na moru" i "Diffusion-based Ergodic Coverage for Robotics". Bavi se metodama rekonstrukcije strujnog polja mora te simulacijama advekcije polja gustoće vjerojatnosti u zadacima traženja bespilotnim letjelicama. Područja njegova znanstvenog interesa obuhvaćaju eksperimentalnu mehaniku fluida, računalnu dinamiku fluida, tehnike optimizacije i autonomno upravljanje bespilotnim letjelicama.

Hrvoje Gotovac

Izogeometrijski neuralni operatori u računalnoj mehanici

Sažetak predavanja

Izogeometrijska analiza (**IGA - I**so**G**eometric **A**nalysis) ima značajno mjesto zadnja dva desetljeća u računalnoj mehanici, prije svega zbog univerzalnog korištenja svojstava spline baznih funkcija čime je omogućeno zajedničko modeliranje geometrije (NURBS kao CAD standard), materijala, opterećenja i samog rješenja. U odnosu na klasične numeričke tehnike, IGA omogućuje više-rezolucijski pristup sa adaptivnim hijerahijskim postupcima, veću točnost, bolja konvergencijska svojstva te veću glatkost rješenja sa spline baznim funkcijama većeg reda nego što je to slučaj kod npr. FEM Lagrangeovih polinoma. Postavlja se pitanje kakvo mjesto mogu zauzeti IGA neuralni operatori u novim računalnim tehnikama sa strojnim učenjem? Posebice je bitan razvoj PINO („Physics Informed Neural Operator") neuralnih operatora koji opisuju odnos preslikavanja ulaznih varijabli (rubni i početni uvjeti, materijal i/ili opterećenje) i izlaznih varijabli kao rješenja raznih fizikalnih problema (npr. piezometarske visine ili brzine kod problema tečenja u podzemnim vodama) čime se otvara mogućnost direktnog, ali i efikasnog inverznog modeliranja. IGA neuralni operatori za razliku od većine klasičnih operatora (Fourierovi spektralni, DeepONet, Konvolucijski,….) koriste dobra svojstva spline baznih funkcija opisujući točno nepravilnu geometriju i sve ostale varijable definirane na njoj. Također, mogu se opisati utjecaji odnosa različitih skala ulaznih i izlaznih varijabli. Za razliku od klasičnih neuralnih mreža ovdje se mogu efikasno koristiti Kolmongorov-Arnold – KAN mreže koje također koriste spline bazne funkcije. Time se za manji broj treniranih parametara, mogu dobiti efikasnija i točnija rješenja. IGA operatori traže relativno mali broj realizacija za učenje čime se za testiranje dobivaju efikasni surogatni računalni modeli koji onda mogu točno i izuzetno brzo riješiti veliki broj realizacija. U ovom predavanju pokazuje se primjena IGA operatora na problem tečenja u heterogenoj poroznoj sredini gdje se povezuje odnos polja hidrauličke propusnosti na polje piezometarske visine. Ovaj operator ima potencijal učenja osnovnih značajki više-rezolucijske distribucije heterogenosti na ključna svojstva tečenja u poroznoj sredini. Na kraju je dan osvrt značajki IGA operatora na buduća istraživanja s inverznim modeliranjem, mogućim uključenjem Bayesovih neuralnih mreža i stohastičkog pristupa.

O predavaču

Hrvoje Gotovac rođen je u Zagrebu, 30.01.1975. Završio je sve stupnjeve obrazovanja u Splitu uključujući sveučilišni studij građevinarstva 1999. godine i poslijediplomski magistarski studij građevinarstva 2005.godine na FGAG-u Split. Doktorski studij je završio na Kraljevskom Tehničkom Sveučilištu u Švedskoj (KTH-Stockholm) 2009. godine. Od 2010. godine nastavlja rad na FGAG-Split kao docent te tamo radi do danas. Postao je redoviti profesor u trajnom zvanju 2024. godine. Bavi se računalnim modeliranjem tečenja i pronosa u multifizikalnim sustavima podzemnih i površinskih voda. Posebno se bavi razvojem numeričkih i stohastičkih metoda u području bezmrežnih metoda temeljenih na spline baznim funkcijama. Objavio je preko 30 znanstvenih članaka u WoS Q1/Q2 časopisima. Sudjelovao je na više od petnaest znanstvenih inozemnih i domaćih projekata od

čega je bio voditelj u 3 HRZZ projekta i 1 IRI-2 projekt. Google zapis njegovih znanstvenih radova je dan na poveznici: https://scholar.google.com/citations?user=LEFJpI4AAAAJ&hl=en&oi=ao.

Goranka Štimac Rončević

Primjena fizikalno informiranih neuronskih mreža u analizi vibracija greda

Sažetak predavanja

U predavanju će se prikazati primjena fizikalno informiranih neuronskih mreža (eng. Phisically Informed Neural Networks – PINN) u određivanju vlastitih frekvencija Euler–Bernoullijeve grede, što predstavlja važan problem u analizi dinamičkog ponašanja konstrukcija. Posebna će se pozornost posvetiti usporedbi klasičnog PINN pristupa i PINN metode temeljene na Rayleighjevu kvocijentu. Najprije će biti objašnjeni osnovni principi PINN metode, uključujući formulaciju diferencijalnih jednadžbi i rubnih uvjeta kroz funkciju gubitka. Naglasit će se izazovi primjene klasičnog PINN pristupa na probleme vlastitih vrijednosti, poput pojave trivijalnih rješenja i poteškoća u konvergenciji. U nastavku će se predstaviti PINN metoda koja koristi Rayleighjev kvocijent, pri čemu se vlastite frekvencije određuju izravno kroz fizikalno utemeljenu optimizacijsku formulaciju. Analizirat će se utjecaj takvog pristupa na stabilnost učenja, brzinu konvergencije i točnost rezultata. Predavanje će završiti usporedbom dobivenih rezultata za oba pristupa, s naglaskom na njihove prednosti, ograničenja i mogućnosti primjene u problemima strukturne dinamike i analize vibracija.

O predavačici

Goranka Štimac Rončević rođena je 6. rujna 1982. u Rijeci. Na Tehničkom fakultetu Sveučilišta u Rijeci zapošljava se 2006. godine kao znanstvena novakinja-asistentica na Zavodu za tehničku mehaniku te 2012. godine brani doktorski rad i stječe naziv doktorice tehničkih znanosti iz znanstvenih polja strojarstvo i temeljne tehničke znanosti. U listopadu 2016. godine izabrana je u zvanje docentice. Od listopada 2021. radi na radnom mjestu izvanredne profesorice te drži vježbe ili predavanja iz sljedećih kolegija: Mehanika II, Kinematika, Dinamika, Inženjerska mehanika II te Regulacija i upravljanje dinamičkim sustavima. Uz rad u nastavi aktivno se bavi znanstvenim radom, pri čemu njezini znanstveni i stručni interesi uključuju analizu i modeliranje problema u mehanici, s posebnim naglaskom na vibracije te dinamiku strojeva i konstrukcija. Njezin istraživački rad obuhvaća teorijske i primijenjene aspekte strukturne dinamike i analize vibracija, kao i razvoj računalnih modela za inženjerske primjene. Autorica ili koautorica je 47 znanstvenih radova objavljenih u međunarodnim časopisima ili zbornicima međunarodnih znanstvenih skupova. Koautorica je knjige: *Mehatronika - odabrane komponente i njihova primjena*, koja je izdana 2022. godine. Od 2008. članica je Hrvatskog društva za mehaniku i Hrvatskog društva za teoriju strojeva i mehanizama. Aktivno se služi engleskim jezikom. Udana je i majka dvoje djece.

Marta Alvir

Primjena strojnog učenja za analizu podmorskih ispusta

Sažetak predavanja

U sklopu ovog predavanja bit će prikazana primjena računalne dinamike fluida i strojnoga učenja u svrhu analize miješanja morske i otpadne vode iz podmorskih ispusta pri čemu nastaju uzgonski mlazovi. Otpadna voda sadrži različite vrste nečistoća poput bakterija, mikroplastika, toksina, metala, velike količine soli te može imati značajne varijacije u temperaturi. Kako bi se minimizirali negativni učinci onečišćenja iz podmorskih ispusta na morski ekosustav, potrebno je postići što bolje miješanje. Stoga je prilikom planiranja izgradnje ispusta, potrebno modelirati miješanje otpadne i morske vode za veći broj potencijalnih uvjeta strujanja, te ovisno o tome odabrati odgovarajuću geometriju

podmorskog ispusta i parametre rada. S obzirom da su takve numeričke simulacije dugotrajne, u sklopu ovog predavanju će biti prikazana procedura za navedenu analizu putem modela strojnog učenja i Shapleyjevog aditivnog objašnjenja (SHAP) što predstavlja značajno brži postupak, te omogućava objašnjenje rezultata dobivenih putem modela strojnog učenja. Procedura se bazira na izradi baze podataka na temelju velikog broja OpenFOAM numeričkih simulacija uzgonskih mlazova koje predstavljaju različite uvijete strujanja. Numeričke simulacije su validirane s prethodnim eksperimentalnim podatcima. Rezultati će biti prikazani za više modela strojnog učenja, uz analizu rezultata utjecajnosti varijabli putem SHAP metode. Dobiveni rezultati ukazuju na veliki potencijal strojnog učenja kod modeliranja onečišćenja u moru prilikom rada podmorskih ispusta.

O predavačici

Dr. sc. **Marta Alvir**, mag. ing. mech. rođena je 1996. godine u Rijeci. Na Tehničkom fakultetu, Sveučilišta u Rijeci završila je prijediplomski studij 2018. te 2020. godine diplomski sveučilišni studij strojarstva, smjer Računarska mehanika i inženjerstvo. Doktorirala je 2024. godine. Radila je kao asistentica u okviru programa "Projekt razvoja karijera mladih istraživača - izobrazba novih doktora znanosti" Hrvatske zaklade za znanost, na temelju projekta "Računalni model strujanja, poplavljivanja i širenja onečišćenja u rijekama i obalnim morskim područjima". Dobitnica je Rektorove nagrade za izvrsnost u akademskoj godini 2022./2023., te nagrade Zaklade Sveučilišta u Rijeci za 2022. godinu. Trenutačno, radi kao viša asistentica, te aktivno sudjeluje u realizaciji nastave, te većem broju domaćih i međunarodnih projekta na teme koje uključuju računalnu dinamiku fluida, strujanje u obalnom području, strojno učenje, paralelno računanje i obnovljive izvore energije.

Martin Zlatić

Termomehanički proširene neuronske mreže: od polikonveksnosti do konkavnosti

Sažetak predavanja

U predavanju se predstavlja primjena neuronskih mreža kao zamjena za klasične termomehaničke modele kako bi se povećala fleksibilnost pri modeliranju i uklonila potreba za pronalaskom i prilagođavanjem različitih klasičnih modela. Sam model pripada širem pristupu modeliranja fizikalno proširenim neuronskim mrežama gdje su fizikalna ograničenja uključena u arhitekturu neuronske mreže i u njeno treniranje. Predavanje se sastoji od kratkog uvoda gdje je dana motivacija za modeliranje neuronskim mrežama i kratki pregled stanja u modeliranju termomehaničkog ponašanja neuronskim mrežama. Potom je predstavljen unaprijeđeni fizikalno prošireni model u kojem su ugrađena ograničenja poput polikonveksnosti u gradijentu deformiranja, konkavnosti u temperaturi, termodinamičke konzistencije, normalizacije energije i naprezanja. Predstavit će se sama arhitektura mreže koja odražava aditivnu konstrukciju Helmholtzove slobodne energije, te nova strategija treniranja na naprezanjima gdje je pretpostavljeno izentropsko stanje. Takva strategija treniranja doprinosi ravnomjernijem udjelu pojedinih dijelova mreže u funkciji cilja te smanjuje pristranost prilikom treniranja. Na kraju predavanja će biti predstavljeni računalni primjeri s neuronskom mrežom ugrađenom u program Abaqus.

O predavaču

Martin Zlatić, rođen 18.3.1996. u Rijeci, je viši asistent na Tehničkome Fakultetu Sveučilišta u Rijeci. Završio je diplomski studij strojarstva u Rijeci 2019. te doktorski studij na Tehničkom Fakultetu 2025. Sudjeluje u izvođenju nastave na prijediplomskoj i diplomskoj razini, te je objavio 4 znanstvena rada u međunarodnim časopisima na temu primjene neuronskih mreža u mehanici čvrstih tijela, 3 članka kao prvi autor s primjenom na hiperelastičnosti i 1 članak kao koautor s primjenom na ugljičnim nanocijevima. Trenutno znanstveno istraživanje je usmjereno na fizikalno proširene neuronske mreže te njihova primjena na različitim materijalnim ponašanjima poput termoelastičnosti.