HDM

HRVATSKO DRUŠTVO ZA MEHANIKU

ZAGREB – OSIJEK – RIJEKA – SL. BROD – SPLIT

Predavanje:

INVERZNO MODELIRANJE MIKROARMIRANIH BETONSKIH GREDA S KONTROLIRANIM NAGIBOM ČELIČNIH VLAKANA

dr. sc. Tea Sulovsky, mag. ing. aedif.

Sveučilište u Rijeci, Građevinski fakultet, Zavod za računalno modeliranje materijala i konstrukcija

Sažetak:

Beton armiran čeličnim vlaknima (eng. *fibre-reinforced concrete*, FRC) kompozitni je materijal u kojem vlakna premošćuju pukotine i povećavaju duktilnost i žilavost pri lomu. Norma EN 1992-1-1:2023 uključuje proračun FRC konstrukcija (Aneks L), u kojem faktor orijentacije vlakana κO skalira rezidualne vlačne čvrstoće. Preporučena vrijednost je κO = 0,5, a za točnije vrijednosti norma traži ispitivanja ili teorijski utemeljene pristupe, koji zasad ne postoje.

U prethodnoj fazi ovog istraživanja razvijen je pojednostavljeni deterministički model savijanja grede u tri točke koji povezuje lokalnu interakciju vlakna i matrice s globalnim odzivom grede, izraženim kroz pomak otvora pukotine (eng. *crack-mouth opening displacement*, CMOD). Na temelju tog modela razvijen je inverzni postupak za identifikaciju parametara FRC-a koji nisu izravno mjerljivi, pri čemu se pokazalo da pouzdanost identifikacije ovisi o veličini ispitnog uzorka.

Model pretpostavlja vlakna okomita na pukotinu i čupanje kao jedini mehanizam popuštanja. Nagib vlakna može se uvesti rastavom sile izvlačenja po kutu, ali takav pristup vrijedi isključivo kada vlakno popušta čupanjem. Literatura pokazuje da se kod nagnutih vlakana mehanizam popuštanja mijenja: javljaju se odlamanje betonske matrice oko vlakna, savijanje i duktilna deformacija vlakna te slom samog vlakna.

U okviru HRZZ projekta INCLINED-FRC (PDIP-2026) vlakna će se kontrolirano ugrađivati pod kutovima od 0° do 60°. Mehanizmi sloma prepoznavat će se na razini jednog vlakna iz krivulja sila-pomak, a na razini grede kamerom uz korelaciju digitalne slike. Stvarno ostvareni kut vlakana u betonskim uzorcima validirat će se rendgenskom mikrotomografijom. U samom modelu prepoznavanje mehanizma sloma iz oblika krivulje planira se metodama strojnog učenja, u okviru

hibridnog modela u kojem deterministička formulacija ostaje temelj, a parametri zadržavaju fizikalno značenje potrebno za inverzno određivanje κO i ostalih parametara.

