

UDK 624.011.1.001.3

Primljeno 2. 8. 2005.

# Razredba drvene građe

Vlatka Rajčić, Adriana Bjelanović

## Ključne riječi

drvena građa,  
razredba,  
hrvatski propisi,  
EN 338,  
mehanička svojstva,  
neuralna mreža

## Key words

timber,  
classification,  
Croatian regulations,  
EN 338,  
mechanical properties,  
neural network

## Mots clés

bois de construction,  
classification,  
règlements croates,  
EN 338,  
propriétés mécaniques,  
réseau neural

## Ключевые слова

строительный  
лесоматериал,  
классификация,  
хорватские правила,  
EN 338,  
механические свойства,  
невральная сеть

## Schlüsselworte

Bauholz,  
Klassifizierung,  
kroatische Vorschriften,  
EN 338,  
mechanische  
Eigenschaften,  
Neuralnetz

V. Rajčić, A. Bjelanović

Izvorni znanstveni rad

## Razredba drvene građe

Opisuje se trenutno stanje razredbe drvene građe u nas u odnosu na prilagodbe sustavu klasifikacije prema EN 338. Istaknuto je da rezultati brojnih ispitivanja drvene građe provedenih u nas pokazuju da su vrijednosti nekih mehaničkih svojstava ispitane građe veće od onih prema EN 338 s odgovarajućim modulom elastičnosti. Razmatra se i prijedlog za poboljšanje koji se može primijeniti u prijelaznom razdoblju, a zasnovan je na upotrebi neuralne mreže kao pomoćne tehnike.

V. Rajčić, A. Bjelanović

Original scientific paper

## Classification of timber

The current classification of timber in our country is described in the light of approximation to the classification system according to EN 338. It is emphasised that results obtained by numerous timber tests conducted in our country show that the values of some mechanical properties of tested timber are higher when compared to those based on EN 338, for the similar modulus of elasticity. The proposal is given for improvement that can be applied in transition period, based on the use of neural network as an accessory technique.

V. Rajčić, A. Bjelanović

Ouvrage scientifique original

## Classification de bois de construction

La classification de bois de construction couramment utilisée dans notre pays est décrite sous l'aspect de l'approximation au système de classification selon la norme EN 338. Il est souligné que les résultats obtenus au cours de nombreux essais faits dans notre pays montrent que les valeurs de quelques propriétés mécaniques de bois soumis à l'essai sont plus élevées que ceux basées sur la norme EN 338, pour le module d'élasticité similaire. Une recommandation est donnée pour les améliorations qui peuvent être faites dans la période de transition, basées sur l'utilisation du réseau neural qui servirait comme une technique accessoire.

В. Райčić, А. Беланович

Оригинальная научная работа

## Классификация строительного лесоматериала

В работе описывается состояние в данный момент классификации строительного лесоматериала у нас по отношению к приспособливанию системе классификации EN 338. Подчёркнуто, что результаты многочисленных испытаний строительного лесоматериала, проведённых у нас, показывают, что значения неких механических свойств испытанного материала превосходят, чем те согласно EN 338 с соответствующим модулем упругости. Рассматривается и предложение по улучшению, которое может применяться в переходном периоде, а основанное на употреблении невральной сети как вспомогательной техники.

V. Rajčić, A. Bjelanović

Wissenschaftlicher Originalbeitrag

## Bauholzklassifizierung

Beschrieben ist der jetzige Stand der Bauholzklassifizierung in Kroatien im Bezug zur Anpassung an das Klassifizierungssystem nach EN 338. Es wird hervorgehoben dass die Ergebnisse zahlreicher in Kroatien durchgeführter Bauholzuntersuchungen zeigen dass die Werte einiger mechanischer Eigenschaften des Bauholzes grösser sind als die nach EN 338 mit entsprechendem Elastizitätsmodul durchgeführt. Man betrachtet einen Vorschlag für die Verbesserung der in der Übergangszeit angewendet werden könnte. Diesen Vorschlag begründet man auf der Benutzung des Neuralnetzes als Behelfstechnik.

Autori: Prof. dr. sc. **Vlatka Rajčić**, dipl. ing. građ., Građevinski fakultet Sveučilišta u Zagrebu;  
doc. dr. sc. **Adriana Bjelanović**, dipl. ing. građ., Građevinski fakultet Sveučilišta u Rijeci

## 1 Uvod

U stalnom i primjetnom razvoju inženjerske discipline graditeljstva drvenim materijalom vrlo je važna uloga nove europske generacije norma, posebice Eurokoda 1 i Eurokoda 5 (EC5). Međusobna ekonomska povezanost Hrvatske s Europskom unijom postavlja zahtjev prilagođavanja skupu norma, nazivlja, oznaka i pravila. Od sekundarne je važnosti kako će se naša buduća norma zvati, ali je primarni interes, vezan za razvoj drvenih konstrukcija u nas, da se pritom ne mimoilazi izvorni sadržaj eurokodova. U EU je EC5 nedavno usvojen kao vrijedeća norma te se u svim zemljama članicama EU moraju izvršiti sva potrebna usklađivanja i prilagodbe novoj normi. Mi smo trenutno u prijelaznom razdoblju primjene vrijedećih norma koje usvajaju koncept dopuštenih naprezanja i provjere novih norma. U Njemačkoj, za koju smo i u prethodnim razdobljima bili najviše vezani što se tiče usvajanja njihovih norma za proračun, izvođenje i zaštitu drvenih konstrukcija, Eurokod 5 je, kao DIN ENV 1995 dio 1-1, uveden u Baden-Württembergu u norme građevinskog nadzora zajedno sa nacionalnim dokumentom za primjenu norme DIN ENV 1995 dio 1-1 (kraće NAD). Zbog te činjenice, uz dozvolu glavne nadzorne institucije za graditeljstvo, u praksi se alternativno mogu rabiti norme DIN 1052. Dosadašnja naša povezanost s DIN-om razlog je što se u sadašnjem razdoblju provjere novih norma zasnovanih na konceptu graničnih stanja često pozivamo na nacrt (*Entwurf*) DIN-1052:2000-05, zasnovan na EC5 i koristimo se njihovom razredbom drvene građe, to više što je Državni zavod za normizaciju i mjeriteljstvo RH, zbog manjka financijskih sredstava, jasno dao do znanja kako u doglednom vremenu neće podržati ulaganja u ispitivanja vrsta drva i određivanje karakterističnih čvrstoća drva kao ni kalibraciju parcijalnih koeficijenata za drvo kao materijal [3].

## 2 Trenutno stanje u području klasifikacije drvene građe

Rad sadrži raspravu o klasifikacijskom sustavu drvene građe za elemente konstrukcija prema EN 338 i trenutnog sustava za klasifikaciju drva u Hrvatskoj prema HRN.U.D0.001. (za vizualnu klasifikaciju to je zapravo u cijelosti preuzet DIN 4074-1, a za klase drva DIN 4074-2 (12/58) također u bivšoj Jugoslaviji preuzet u cijelosti). Prema rezultatima nekolicine eksperimentalnih istraživanja te podataka o ispitivanjima drva ugrađenog u niz konstrukcija izvedenih na području RH iz arhiva Odjela za drvene konstrukcije Građevinskog fakulteta Sveučilišta u Zagrebu [1, 2, 4, 8] i drugih Građevinskih fakulteta [5, 7] te instituta [6], vrste drva koje se najčešće rabe za elemente u drvenim konstrukcijama u Hrvatskoj ne mogu se s glavnom mehaničkih karak-

teristika svrstati u jedinstvenu klasu prema EN 338. Za određene vrijednosti modula elastičnosti, naše vrste drva imaju veće vrijednosti karakterističnih čvrstoća nego što su one koje pripadaju toj klasi prema modulu elastičnosti. Upotrebljavajući vrijednosti karakterističnih čvrstoća prema EN 338, drvo bi se neekonomično rabilo jer bi bilo predimenzionirano.

Za zemlje u tranziciji, kao što je Hrvatska koje se koriste Eurokodom 5 kao normom koja nije ozakonjena, ali se smije primjenjivati paralelno s vrijedećom nacionalnom normom i nisu sačinile tablice karakterističnih vrijednosti mehaničkih karakteristika za najviše upotrebljavane domaće vrste drva, u ovome radu predlaže se u prijelaznom razdoblju, dok se ne naprave tablice, klasifikacija uz uporabu neuralnih mreža zasnovanih na rezultatima nedestruktivnih i destruktivnih ispitivanja drvenih uzoraka različitih botaničkih vrsta.

## 3 Prijedlog poboljšanja u području klasifikacije drvene građe

U Hrvatskoj se klasifikacija drvene građe izvodi tradicionalno vizualnim putem uzimajući u obzir smanjivanja dopuštenih naprezanja u drvu s obzirom na postojanje kvrga i većih širina godova no što je to u granicama normale. Kod nas je vrlo mali postotak pilana koje se u svom sustavu klasificiranja drva koriste strojnom klasifikacijom. Pretpostavlja se, dakle, da vizualno klasificiranje ima svoja ograničenja, budući da odluka o klasi ovisi isključivo o prosudbi klasifikatora koja nikada ne može biti u potpuno objektivna.

Prema nizu istraživanja i izvještaja o mehaničkim karakteristikama drva ugrađenog u konstrukcije, rađenim na Odjelu za drvene konstrukcije Građevinskog fakulteta Sveučilišta u Zagrebu i nekim drugim građevinskim fakultetima te institutima, razvidno je da bi automatsko preuzimanje klasa čvrstoća prema EN 338 moglo izazvati određene ekonomske gubitke, što bismo zapravo s novim sustavom htjeli izbjeći. Na žalost prisjetimo se da je Hrvatska tipična zemlja koja izvozi drvo kao sirovinu i uvozi skupe dizajnirane drvene proizvode. I dosadašnjim sustavom vizualne klasifikacije nanosene su goleme štete zbog neekonomičnog iskorištavanja drva u graditeljstvu, pa bi novi sustav klasifikacije upravo trebao poticati optimalno i ekonomično iskorištavanje drvene građe.

U Hrvatskoj se za uporabu u graditeljstvu uglavnom rabe sljedeće četiri botaničke vrste drva: bor (*Pinus silvestris*), jelovina (*Abies alba*), smreka (*Picea excelsa*) kao meka drva te hrast (*Quercus pedunculata*) kao predstavnik tvrdog drva.

Zašto bi klasifikacija prema EN 338 mogla uzrokovati ekonomske gubitke? Polazeći od eksperimentalnih po-

dataka za meko drvo rađenih na više od 100 uzoraka za svaku mehaničku karakteristiku drva destruktivnim putem, prema vrijedećim hrvatskim normama, te varijacijom udjela vlage u drvu od 11,5% – 14%, dobivene su sljedeće karakteristične veličine mehaničkih svojstava drva. (tablica 1.). Sve karakteristične čvrstoće svedene su na vlažnost drva od 12%.

Vrijednost 5%-tne fraktila, tj  $X_k$ , može se odrediti prema EC5 kao:

$$X_k = k_1 \cdot \bar{X}$$

gdje je:

$$k_1 = e^{[-(2.645+1/\sqrt{n})v(x)+0.15]} \quad (1)$$

U prethodnom izrazu (1) vrijednost  $X_k$  predstavlja karakterističnu vrijednost, a  $\bar{X}$  označava srednju ili prosječnu vrijednost nekog mehaničkog svojstva drva. Vrijednost  $v(x)$  ne smije biti uzeta manja od 0,01 i predstavlja koeficijent varijacije. Vrijednost faktora  $k_1$  definirana je u Dodatku A (ENV 1995-1-1:1993, izraz A2. 2b ili podaci iz tablice A2 Dodatka A)) i predstavlja najveću vrijednost koju proizvođač smije deklarirati kao karakterističnu vrijednost. Vrijednost ovog faktora ovisi o koeficijentu varijacije i veličini uzorka od ( $n$ ) komada (najmanji broj uzoraka jest 30 komada od kojih svaki mora biti testiran u skladu s odgovarajućom procedurom i normom).

Tablica 1. Vrijednosti mehaničkih karakteristika za meko drvo u Hrvatskoj prema [1, 2, 3, 4, 5, 6, 7, 8] u usporedbi s klasama danim prema EN338

| Mehanička karakteristika materijala | Karakteristična vrijednost meh. karakteristika [Mpa] | Usporedne klase čvrstoće prema EN 338 | Razlika [%]* |
|-------------------------------------|--|---------------------------------------|--------------|
| $E_{0,mean}$                        | 12,0   | C27                                   |              |
| $E_{0,05,k}$                        | 7,8  | C30                                   |              |
| $f_{m,k}$ savijanje                 | 55,4   | C40*                                  | 38%          |
| $f_{c,0,k}$ tlak II vlaknima        | 25,0   | C40                                   |              |
| $f_{c,90,k}$ tlak $\perp$ na vlakna | 7,2  | C40*                                  | 14%          |
| $f_{t,0,k}$ vlak II na vlakna       | 35,0   | C40*                                  | 45%          |
| $f_{v,k}$ posmik                    | 6,4  | C40*                                  | 68%          |
| $\rho_{mean}$ gustoća               | 420  | C40                                   |              |

\* vrijednosti označene u postocima odnose se na razlike između naših mjerenih vrijednosti i odgovarajućih karakterističnih čvrstoća za klasu najvećih mehaničkih karakteristika C40 prema EN 338 sustavu klasifikacije

Isti problem relativno velikog disproporcije između vrijednosti MOE i karakterističnih vrijednosti čvrstoća postoji u odnosu na tablice za tvrdo drvo prema EN 338 i za hrast kao najučestaliju vrstu tvrdog drva koja se iskorištava u Hrvatskoj (tablica 2.). Tvrdo se drvo inače puno rjeđe rabi za konstruktivne elemente današnjih drvenih konstrukcija nego meka građa, ali ljudi su psihološki vezani za hrast kao za pojam kvalitete, čvrstoće i sigurnosti. Tradicionalno su se drvene kuće u Hrvatskoj gradile hrastovinom kao i današnja etnonaselja te objekti u nacionalnim parkovima i sl.

Tablica 2. Vrijednosti mehaničkih karakteristika za tvrdo drvo u Hrvatskoj prema [1, 2, 3] u usporedbi s klasama danim prema EN 338

| Mehanička karakteristika | Vrijednost [Mpa] | Usporedne klase čvrstoće prema EN 338 | Razlika [%] |
|--------------------------|------------------|---------------------------------------|-------------|
| $E_{0,mean}$             | 13.8             | D50                                   |             |
| $E_{0,05,k}$             | 11.5             | D50                                   |             |
| $f_{m,k}$                | 75.4             | D70*                                  | 8%          |
| $f_{c,0,k}$              | 42.0             | D70                                   |             |
| $f_{c,90,k}$             | 12.0             | D60-D70                               |             |
| $f_{t,0,k}$              | 38.0             | D60-D70                               |             |
| $f_{v,k}$                | 7.5              | D70*                                  | 25%         |
| $\rho_{mean}$            | 670              | D50                                   |             |

Za usporedbu s tablicama dobivenim ovim istraživačkim radom, daju se tablice za meko i tvrdo puno drvo prema EN 338 i DIN ENV 1995. (DIN 4074-1)

Karakteristične vrijednosti čvrstoće na vlak i savijanje odnose se na usporednu visinu presjeka od 150 mm. Za visine presjeka koje su manje od usporedne, projektirane vrijednosti čvrstoće treba množiti s koeficijentom utjecaja visine,  $k_h$ , prema (2):

$$k_h = \min \left\{ \begin{array}{l} (150/h)^{0,2} \\ 1,30 \end{array} \right. \quad (2)$$

Tablica 5. priložena je zato što se u Hrvatskoj u prijelaznom razdoblju provjere novih norma dosta primjenjuje DIN ENV 1995. jer smo i do sada uglavnom bili orijentirani na njemačke propise [9]. U istoj su tablici 5. i klase za strojno klasificiranje (MS klase), ali je obveza konstruktora da se prije projektiranja s MS klasom uvjeri da je takvo klasificiranje doista moguće ostvariti. Iz tablice se također vidi da s većim klasama rastu čvrstoće drva, ali i vrijednosti krutosti, što se odražava na dokaz uporabljivosti. Također, povećanje mase drva utječe i na rast vrijednosti nosivosti spajala.

Tablica 3. Karakteristične vrijednosti čvrstoće i krutosti u N/mm<sup>2</sup> i karakteristične gustoće u kg/m<sup>3</sup> za puno meko drvo prema EN 338

| Klase prema EN 338 za meko drvo (1995.) |               | C 14 | C 16 | C 18 | C 22  | C 24  | C 27  | C 30  | C 35  | C 40  |
|---|---------------|------|------|------|-------|-------|-------|-------|-------|-------|
| <b>Čvrstoće</b>                         |               |      |      |      |       |       |       |       |       |       |
| savijanje                               | $f_{m,k}$     | 14,0 | 16,0 | 18,0 | 22,0  | 24,0  | 27,0  | 30,0  | 35,0  | 40,0  |
| vlak                                    | $f_{t,0,k}$   | 8,0  | 10,0 | 11,0 | 13,0  | 14,0  | 16,0  | 18,0  | 21,0  | 24,0  |
| vlak ⊥                                  | $f_{t,90,k}$  | 0,3  | 0,3  | 0,3  | 0,3   | 0,4   | 0,4   | 0,4   | 0,4   | 0,4   |
| tlak                                    | $f_{c,0,k}$   | 16,0 | 17,0 | 18,0 | 20,0  | 21,0  | 22,0  | 23,0  | 25,0  | 26,0  |
| tlak ⊥                                  | $f_{c,90,k}$  | 4,3  | 4,6  | 4,8  | 5,1   | 5,3   | 5,6   | 5,7   | 6,0   | 6,3   |
| posmik i torzija                        | $f_{v,k}$     | 1,7  | 1,8  | 2,0  | 2,4   | 2,5   | 2,8   | 3,0   | 3,4   | 3,8   |
| <b>Moduli</b>                           |               |      |      |      |       |       |       |       |       |       |
| srednji E modul                         | $E_{0,mean}$  | 7000 | 8000 | 9000 | 10000 | 11000 | 12000 | 13000 | 13000 | 14000 |
| karakteristični E modul                 | $E_{0,05}$    | 4700 | 5400 | 6000 | 6700  | 7400  | 8000  | 8000  | 8700  | 9400  |
| srednji E modul ⊥                       | $E_{90,mean}$ | 230  | 270  | 300  | 330   | 370   | 400   | 400   | 430   | 470   |
| srednji modul posmika                   | $G_{mean}$    | 440  | 550  | 560  | 630   | 690   | 750   | 750   | 810   | 880   |
| gustoća                                 | $\rho_k$      | 290  | 310  | 320  | 340   | 350   | 370   | 380   | 400   | 420   |

Vrijednosti čvrstoća navedenih u tablici 5., prema NAD-u, ne treba modificirati ( $k_h = 1$ ). To je dopušteno zahvaljujući srednjoeuropskoj praksi piljenja drvene građe koja isključuje učinak djelovanja volumena elementa drva na čvrstoću.

### 3.1 Uporaba neuralne mreže kao pomoćne tehnike pri klasifikaciji drvene građe

Procedura koja se predlaže ovim radom sastoji se od nedestruktivnog načina određivanja modula elastičnosti

drvenih elemenata, destruktivnog određivanja vrijednosti lomnih čvrstoća te primjene neuralne mreže koja ujedinijuje utjecaj niza varijabli na izlazne rezultate tj. karakteristične čvrstoće. Ulazne su varijable za učenje neuralne mreže: dimenzije uzoraka drva, gustoća, postotak vlažnosti u drvu, rubni uvjeti, dinamički modul elastičnosti dobiven nedestruktivnim ispitivanjima, dok su izlazne varijable vrijednosti karakterističnih čvrstoća dobivene prema propisu iz lomnih čvrstoća destruktivnim putem. To je *test-set* za učenje neuralne mreže za pojedinu botaničku vrstu drva.

Tablica 4. Karakteristične vrijednosti čvrstoće i krutosti u N/mm<sup>2</sup> i karakteristične gustoće u kg/m<sup>3</sup> za tvrdo puno drvo prema EN 338

| Klase prema EN 338 za tvrdo drvo (1995.) |                | D 30  | D 35  | D 40  | D 50  | D 60  | D 70  |
|--|----------------|-------|-------|-------|-------|-------|-------|
| <b>Čvrstoće</b>                          |                |       |       |       |       |       |       |
| savijanje                                | $f_{m,k}$      | 30,0  | 35,0  | 40,0  | 50,0  | 60,0  | 70,0  |
| vlak                                     | $f_{t,0,k}$    | 18,0  | 21,0  | 24,0  | 30,0  | 36,0  | 42,0  |
| vlak ⊥                                   | $f_{t,90,k}$   | 0,6   | 0,6   | 0,6   | 0,6   | 0,7   | 0,9   |
| tlak                                     | $f_{c,0,k}$    | 23,0  | 25,0  | 26,0  | 29,0  | 32,0  | 34,0  |
| tlak ⊥                                   | $f_{c,90,k}$   | 8,0   | 8,4   | 8,8   | 9,7   | 10,5  | 13,5  |
| posmik i torzija                         | $f_{v,k}$      | 3,0   | 3,4   | 3,8   | 4,6   | 5,3   | 6,0   |
| <b>Moduli</b>                            |                |       |       |       |       |       |       |
| srednji E modul                          | $E_0, mean$    | 10000 | 10000 | 11000 | 14000 | 17000 | 20000 |
| karakteristični E modul                  | $E_{0,05}$     | 8000  | 8700  | 9400  | 11800 | 14300 | 16800 |
| srednji E modul ⊥                        | $E_{90, mean}$ | 640   | 690   | 750   | 930   | 1130  | 1330  |
| srednji modul posmika                    | $G_{mean}$     | 600   | 650   | 700   | 880   | 1060  | 1250  |
| gustoća                                  | $\rho_k$       | 530   | 560   | 590   | 650   | 700   | 900   |

Tablica 5. Karakteristične vrijednosti čvrstoće i krutosti u N/mm<sup>2</sup> i karakteristične gustoće u kg/m<sup>3</sup> za puno drvo prema DIN ENV 1995.

| Klase prema DIN 4074-1   |               | S 7 / M S7      | S 10 / MS 10 | S 13  | MS 13 | MS 17 |
|--|---------------|-----------------|--------------|-------|-------|-------|
| <b>Čvrstoće</b>  |               |                 |              |       |       |       |
| savijanje  | $f_{m,k}$     | 16              | 24           | 30    | 35    | 40    |
| vlak   | $f_{t,0,k}$   | 0 <sup>1)</sup> | 14           | 18    | 21    | 24    |
| vlak ⊥   | $f_{t,90,k}$  | 0 <sup>2)</sup> | 0,2          | 0,2   | 0,3   | 0,2   |
| tlak   | $f_{c,0,k}$   | 17              | 21           | 23    | 25    | 26    |
| tlak ⊥   | $f_{c,90,k}$  | 4               | 5            | 5     | 5     | 6     |
| posmik i torzija   | $f_{v,k}$     | 1,8             | 2,5          | 2,5   | 3,0   | 3,5   |
| <b>Moduli</b>  |               |                 |              |       |       |       |
| srednji e modul  | $E_{0,mean}$  | 8000            | 11000        | 12000 | 13000 | 14000 |
| karakteristični e modul  | $E_{0,05}$    | 5400            | 7400         | 8000  | 8700  | 9400  |
| srednji e modul ⊥  | $E_{90,mean}$ | 270             | 370          | 400   | 430   | 470   |
| karakteristični e modul ⊥  | $E_{90,05}$   | 180             | 250          | 270   | 290   | 310   |
| srednji modul posmika  | $G_{0,mean}$  | 500             | 690          | 750   | 810   | 880   |
| karakteristični modul posmika  | $G_{0,05}$    | 330             | 460          | 500   | 540   | 590   |
| gustoća  | $\rho_k$      | 350             | 380          | 380   | 400   | 420   |
| <sup>1)</sup> Za MS 7 vrijedi $f_{t,0,k} = 10 \text{ N/mm}^2$ .<br><sup>2)</sup> Za MS 7 vrijedi $f_{t,90,k} = 0,2 \text{ N/mm}^2$ . |               |                 |              |       |       |       |

Ovdje treba istaknuti da su se u svim destruktivnim laboratorijskim ispitivanjima lomnih čvrstoća upotrebljavali uzorci prema vrijedećim normama (HRN.D.A1.035., HRN.D.A1.045., HRN.D.A1.048., HRN.D.A1.053., HRN.D.A1.046., HRN.D.A1.044). Norme nalažu "čiste", pravilne uzorke s minimalnim otklonima pravca vlakana od paralelnog i bez pogreška tzv. *clear specimens*.

Pošto je mreža "savladala" niz podataka do određene točnosti, izrađuje se RUN-TIME opcija neuralne mreže. Uporabom toga programa omogućeno je objektivnije klasificiranje pri čemu se može značajno poboljšati zakonski vrijedeća vizualna klasifikacija. Osim toga cijela klasifikacija prilagođava se EC5 sustavu. Potom za uzorak odgovarajuće botaničke vrste jednostavnim nedestruktivnim ispitivanjem dinamičkog modula elastičnosti, mjerenjem dimenzija i težine te naučenim korelacijama između svih ulaznih i izlaznih varijabli (slika 1.), moguće je za određenu botaničku vrstu drva dobiti vrijednosti mehaničkih karakterističnih veličina bez potrebe bilo kakvih laboratorijskih destruktivnih ispitivanja, što nam značajno olakšava rad, a daje i objektivnije rezultate.

Uzorcima ili ugrađenim elementima u drvenoj konstrukciji može se pristupiti ultrazvučnim sondama (slike 2. i 3.). U tom slučaju rubni uvjeti nisu ključni. U slučaju dobivanja modula elastičnosti tranzijentnom pobudom udarom uzorka u smjeru pružanja vlakana drva (slika 4.), koristeći se pri tome spektralnim analizatorom za određivanje prve frekvencije i dinamičkog MOE, rubni su uvjeti vrlo bitni.

Procedura pomoćne tehnike pri klasifikaciji sastoji se od mjerenja postotka vlažnosti, dimenzija i težine uzoraka. Svi ti ulazni podaci pohranjuju se u memoriju PC-a. Upotrebom jedne od nedestruktivnih tehnika, program izračunava dinamički MOE i kasnije sve karakteristične vrijednosti mehaničkih svojstava drva koje su nam potrebne pri projektiranju drvenih konstrukcija. Naravno, podrazumijeva se da neuralna mreža primijeni na što više uzoraka koji su i destruktivno ispitani te da se njezini rezultati stalno testiraju nakon određenog broja prolaza.




Slika 1 Između bilo koje dvije ulazne i izlazne varijable moguće je uspostaviti grafički tj. funkcijski odnos, npr. U ovom slučaju ( $f_{c,90,k} - f_m$ )



Slika 2. Ultrazvučno mjerenje MOE u



Slika 3. Ultrazvučni instrument Sylvaduo test s ugrađenim elementima



Slika 4. Određivanje MOE spektralnim analizatorom uz tranzijentnu pobudu impulsnim čekićem

#### 4 Zaključak

Za zemlje u tranziciji koje trenutno nemaju tablice za karakteristične vrijednosti čvrstoća kalibrirane za najčešće upotrebljavane vrste drva u graditeljstvu, ovaj rad donosi informaciju o mogućnostima i proceduri kojom se može poboljšati trenutni vizualni način klasifikacije drva i ekonomski uštediti. S druge strane njome bi se izbjegli veliki troškovi pilana pri prilagođavanju na EC5 sustav, kupovanjem izuzetno skupih sustava za strojno klasificiranje kao npr. DIMTER ili GRECOMATEN koji rade na osnovi mjerenja statičkog modula elastičnosti progibom opterećenjima u radnom području ili nedestruktivnog ultrazvučnog načina određivanja dinamičkog MOE, uz dodatnu primjenu lasera i skenera koji utvrđuju pogreške na uzorku te vlagomjera i preciznih elektronskih vaga.

#### LITERATURA

- [1] Saler, V.: *Bezrazorne metode određivanja mehaničkih karakteristika drva*, magistarska radnja, Sveučilište u Zagrebu, Građevinski fakultet, siječanj 1996.
- [2] Rajčić, V.: *Karakteristike spregnutih nosača drvo-lagani beton*, doktorska disertacija, 2000.
- [3] Bjelanović, A.; Rajčić, V.: *Drvene konstrukcije prema europskim normama*, Hrvatska Sveučilišna naklada i Građevinski fakultet Sveučilišta u Zagrebu, lipanj, 2006.
- [4] Haiman, M.: *Analiza sigurnosti lameliranih nosača*, doktorska disertacija, Građevinski fakultet Sveučilišta u Zagrebu, lipanj 2001.
- [5] Lozančić, S.: *Doprinos spoznajama spregnutih nosača drvo-beton*, doktorska disertacija, Građevinski fakultet Sveučilišta J. J. Strossmayera u Osijeku, prosinac, 2003.
- [6] Gramatikov, K.: *Eksperimentalni i analitički istraživanja na drveni rešetkasto-ramovski nosači*, doktorska disertacija, Institut za zemljotresno inženjerstvo I inženjerska seizmologija na Univerzitetu „Kiril i Metodij“, Skopje, Maj, 1990.
- [7] Đidara, Ž.: *Mogućnost proizvodnje lijepljenih nosača iz mekih listača*, doktorska disertacija, Sveučilište u Zagrebu, Šumarski fakultet, Zagreb, svibanj 1998.
- [8] Gjinolli, Agron E.: *Analiza toka relaksacije napona u zakrivljenim lameliranim elementima*, magistarski rad, Sveučilište u Zagrebu, Građevinski fakultet, Zagreb, 1997.
- [9] STEP 1 Blaß, H. J./ Görlacher, R./ Steck, G.: *STEP 1, Bemessung und Baustoffe*, Fachverlag Holz, Düsseldorf, 1995.