

PODPORA UMETNE INTELIGENCE PRI PROJEKTIH PRENOVE IN UPRAVLJANJA STAVB

ARTIFICIAL INTELIGENCE AS A SUPPORT IN RENOVATION PROJECT AND FACILITY MANAGEMENT

dr. Daniela Dvornik Perhavec, univ. dipl. inž. grad.

daniela.d-perhavec@um.si

red. prof. dr. Danijel Rebolj, univ. dipl. inž. grad.

danijel.rebolj@um.si

Univerza v Mariboru, Fakulteta za gradbeništvo, prometno inženirstvo in arhitekturo, Smetanova 17, 2000 Maribor

red. prof. dr. Milan Zorman, univ. dipl. inž. rač. in inf.

milan.zorman@um.si

Univerza v Mariboru, Fakulteta za elektrotehniko, računalništvo in informatiko, Smetanova 17, 2000 Maribor

ZNANSTVENI ČLANEK

UDK 004.896:725.1(497.4)

Povzetek | Pridobivanje znanja iz podatkov (ang. Knowledge Discovery from Database, krajše KDD) in podatkovno rudarjenje (ang. Data Mining, krajše DM) spadata v področje racionalne umetne inteligence (ang. Artificial Intelligence, krajše AI). Metode umetne inteligence na podlagi podatkovnih baz omogočajo ustvarjanje modelov, odkrivanje novih znanj in napovedovanje novih rešitev. Vključevanje umetne inteligence v različne segmente gradbeništva in gradbene industrije je šele v povojih, kaj kmalu pa si lahko obetamo širšo vključenost, ki bo pogojena z razvojem podatkovnih baz in podatkovnih skladišč. Z uporabo tehnologij BIM pri projektiranju novogradenj bomo dragocene podatke lahko pridobili, za stare, že obstoječe stavbe pa bo podatke treba pridobiti, zbrati, prečistiti in organizirati tako, da jih bomo lahko modelirali s tehnologijami umetne inteligence. V članku predstavljamo uporabo zbranih podatkov kot ideje za pobudo razvoja podatkovnih baz. Predstavljamo rezultate dveh raziskav. V prvi raziskavi smo preučevali karakteristiko »nosilni zid« za stanovanjske stavbe z etažnostjo klet, pritličje, nadstropje in mansarda; stavbe so bile grajene v obdobju med letoma 1857 do 1948. Članek predstavlja dva vidika potrebe po sistematičnem zbiranju, urejanju in skladiščenju podatkov, prvič, kot možnost prikaza uporabe, in drugič, kot ideja za pobudo za razvoj podatkovnih baz. Predstavljamo rezultate dveh študij. V prvi raziskavi smo preučevali značilnost zunanega nosilnega zidu za stanovanjske stavbe s kletjo, pritličjem, prvim nadstropjem in mansardo; stavbe so bile zgrajene med letoma 1857 in 1948. Cilj te raziskave je bil ustvariti model za napovedovanje lastnosti objektov, za katere arhivsko gradivo ne obstaja. V drugi raziskavi smo proučevali kombinacijo značilnosti objektov in porabe toplotne energije v stavbah na Tehniški fakulteti Univerze v Mariboru. Cilj druge študije je razviti model za določitev vpliva posameznih značilnosti predmetov na porabo toplotne energije. Oba modela temeljita na uporabi umetne inteligence pri gradnji odločitvenih dreves.

Ključne besede: stavba, podatkovne baze, umetna inteligenca, podatkovno rudarjenje, odločitvena drevesa

Summary | Knowledge discovery from database (KDD) and data mining (DM) belong to the field of artificial intelligence (AI). Based on the AI methods and a lot of data we can create models, discover new knowledge and predict new solutions. The integration of artificial intelligence in different segments in the construction industry is still in its infancy, but soon we can expect a wider involvement, which will be conditioned by the development of databases and the data warehouses. By using BIM technology when designing new buildings, we can gain valuable information, although information about old existing facilities will also have to be obtained, collected, consolidated and organized in a way that they can be modeled with techniques of artificial intelligence. The paper shows how to use information as an idea for an initiative to developing databases. We present the results of two studies. In the first study, we studied the characteristic "external main wall" for residential buildings with basement, ground floor, first floor and attic, built between 1857 and 1948. The aim of this research was to create a model to predict the characteristics of the object for which the archival material does not exist. In the second study, we studied a combination of characteristics of objects and consumption of thermal energy in the buildings of the Technical Faculty of the University of Maribor. The goal of the second study was to develop a model to determine the impact of individual characteristics of objects on the consumption of thermal energy. Both models are based on the use of artificial intelligence in the construction of decision trees.

Key words: building, databases, artificial intelligence, data mining, decision trees

1 • UVOD

Umetna inteligenca (ang. Artificial Intelligence, krajše AI) je po definiciji področje znanosti, ki spada v informatiko z interdisciplinarnim značajem (Russell, 2004). Z njeno pomočjo lahko na podlagi obstoječih podatkov odkrijemo novo, do zdaj skrito znanje in ga uporabimo za uspešnejše diagnosticiranje, analizo, načrtovanje, trženje, odločitve ipd.

Umetna inteligenca se ukvarja s spoznavanjem in razlago problemov, pri katerih se zahtevajo inteligenten pristop in proučevanje, načrtovanje in razvoj umetno vodenih inteligentnih tehnologij. Z razvojem umetne inteligence sta povezani dve imeni, in sicer Turing (znan po Turingovem stroju) in McCarthy; razvijati se je začela leta 1950 (Gams, 2012). V svetu sicer štejejo za začetek umetne inteligence letnico 1956, ko je McCarthy v ZDA organiziral konferenco, ki je povzročila izbruh navdušenja nad novim pojmom umetna inteligenca, z njo pa so se začeli ukvarjati po vsem svetu.¹ Umetna inteligenca je prepletena z matematiko, nevrologijo, psihologijo, logiko,

¹ Turing je govoril o »machine intelligence« (inteligenci stroja).

filozofijo in drugimi vedami ter obsega vsaj štiri področja (vizualno, govorno, manipulativno in racionalno inteligenco) in več podpodročij. Izvorni cilj umetne inteligence je bil izdelati napravo, ki posnema človeško razmišljanje. Pri tem bi bili vključeni tudi čustva in zavest. Danes je cilj umetne inteligence razvoj tehnologij in naprav, ki se vedejo, kot bi razpolagale z naravno inteligenco. Z njo se razvijajo metode in tehnike reševanja problemov, ki jih je težko rešiti s klasičnimi metodami.

Z metodami umetne inteligence, kot sta metoda pridobivanja znanja iz podatkov (KDD) in metoda podatkovnega rudarjenja (DM), smo preverili možnost odkrivanja novih znanj in uporabnost teh pri ciljno usmerjenem modelu v gradbeništvu. Zanimalo nas je, ali z novo pridobljenim znanjem lahko koristno pomagamo projektantom, vzdrževalcem, načrtovalcem, ki obstoječo stavbo proučujejo in analizirajo zaradi potreb po izdelovanju študij, projektov, investicijske dokumentacije ipd. Nadalje nas je zanimalo, ali z metodami umetne inteligence, natančneje z metodo odločitvenih dreves, lahko zapolnimo vrzel tam, kjer so se projekti v

dolgi zgodovini izgubili, ter je obstoječo stavbo treba spoznati in raziskati z vsemi karakteristikami in materiali.

V skladu z razvojnoraziskovalnim projektom »E-nepremična inženirska zakladnica« smo za ciljno določene stavbe opravili raziskovalni in razvojni del z namenom povezovanja vsebin interdisciplinarne narave, in sicer karakteristične podatke o stavbi in porabi toplotne energije (Dvornik Perhavec, 2015). Največje ovire, na katere smo naleteli pri raziskovalnem delu, so bile naslednje:

- podatkovne baze za tovrstne potrebe ne obstajajo,
- projekti, iz katerih bi lahko pridobili karakteristične podatke o stavbah, so neustrezno arhivirani (razen v pokrajinskih arhivih),
- poraba toplotne energije se beleži za sklop stavb skupaj in ne ločeno za posamezne stavbe.

V 2. poglavju bomo podrobneje predstavili del racionalne inteligence, in sicer metode pridobivanja znanja iz podatkov, in podatkovno rudarjenje. V tretjem poglavju predstavljamo podatkovno modeliranje in proces gradnje odločitvenih dreves. V četrtem poglavju sledi predstavitev rezultatov ter v nadaljevanju zaključek, zahvala in literatura.

2 • ODKRIVANJE ZNANJA V PODATKIH (KNOWLEDGE DISCOVERY FROM DATA) IN PODATKOVNO RUDARJENJE (DATA MINING)

2.1 Splošno

Odkrivanje znanja v podatkih (KDD) je zapleten proces za odkrivanja asociacij, sprememb, anomalij, dogodkov, potencialnih uporabnih in navsezadnje razumljivih vzorcev iz podatkov, ki predstavljajo implicitne, prvotno nepoznane zakonitosti ali informacije v danih podatkih (Witten, 2005).

Definicijo podatkovnega rudarjenja sta postavila Han in Kamber leta 2001 (Han, 2006), in sicer: »Podatkovno rudarjenje je proces odkrivanja zanimivih in pomembnih vzorcev ter znanja iz ogromne količine podatkov, shranjenih v podatkovnih bazah, podatkovnih skladiščih in drugih informacijskih odlagališčih s koriščenjem metod strojnega učenja.« (Han, 2006)

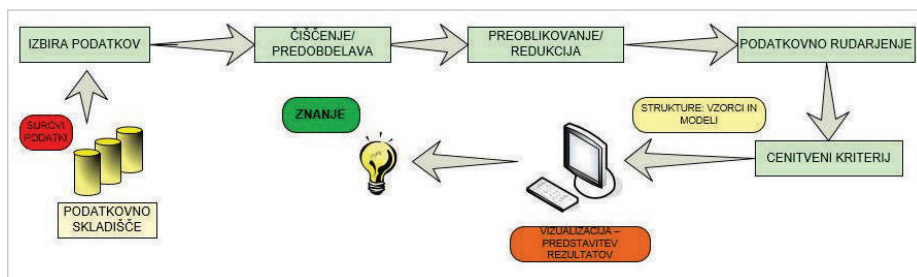
Odkrivanje znanja v podatkih (KDD) je proces (Zorman, 2003), ki vsebuje devet (9) korakov, in sicer od razumevanja uporabe področja za odkrivanje znanja v bazah, ustvarjanja in oblikovanja nabora ciljnih podatkov, čiščenja in predobdelave podatkov (zbrati je treba informacije za model, odločiti o strategijah za obravnavo manjkajočih podatkov in podobno), izbiranja podatkov v odvisnosti od namena naloge. Opraviti je treba izbiro funkcij podatkovnega rudarjenja, izdelati modeliranje in raziskovalno analizo, ki pomeni izbiro algoritmov, izbiro metode ali metod, ki se uporabljajo pri iskanju vzorcev podatkov. Nadalje

2.2 Podatkovno rudarjenje z odločitvenimi drevesi

Odločitvena drevesa spadajo med simbolične metode, veljajo za preprostejše metode strojnega učenja in se uporabljajo za reševanje klasifikacijskih problemov (Zorman, 2003). Učijo se iz informacijskega vira oz. tabele, ki predstavlja učno množico. Imajo opisne in odločitvene attribute. Attribute so lahko diskretni ali zvezni. Pri tem se išče funkcija, ki opisne attribute pretvori v prostor odločitve. Imajo strukturo, ki je podobna hierarhičnim diagramom poteka. Drevo je sestavljeno iz notranjih in zunanjih vozlišč ter vej. Zunanja vozlišča se imenujejo listi. Vsak list predstavlja klasifikacijsko oznako, ki je hkrati rezultat posameznega primera. Postopek generiranja odločitvenega drevesa iz učne množice imenujemo indukcija odločitvenega drevesa. Pri indukciji začnemo s praznim drevesom in

se izvede podatkovno rudarjenje (Data Mining), ki je sedmi korak v postopku KDD in v bistvu predstavlja iskanje vzorcev v določenih reprezentativnih oblikah ali nizu teh reprezentacij (Oteiza, 2011). Sledita tolmačenje in pojasnjevanje rezultatov z možnostjo vrnitve za nekaj korakov nazaj ali od začetka do sedmega koraka z dodatnimi ponovitvami. Ta korak lahko vključuje tudi vizualizacijo. Sledijo uporaba in predstavitev odkritega znanja ter predstavitev uporabe znanja in vključevanja poznavanja v drug sistem za nadaljnje ukrepanje zainteresiranim stranem oz. končnemu uporabniku.

Proces podatkovnega rudarjenja izvajamo po naslednji shemi:



Slika 1 • Proces podatkovnega rudarjenja.

Podatkovno rudarjenje praviloma izkorišča metode s področja inteligentnih sistemov, strojnega učenja in razpoznavanja vzorcev, ki omogoča, da se odkriva implicitno, prej

celotno množico učnih vzorcev. Zvezni attribute niso primerni za gradnjo odločitvenega drevesa, zato jih moramo preslikati v diskretno obliko. Način preslikave zveznega attribute v diskretni prostor, poimenovan tudi diskretizacija, je zelo pomemben in lahko odločilno vpliva na uspeh ali neuspeh zgrajenega odločitvenega drevesa. Odločitvena drevesa ne zahtevajo nastavljanja parametrov oziroma posebnega znanja o učni množici. Pomembna lastnost je tudi ta, da je posamezne vzorce mogoče opisati z velikim številom attributev oziroma lastnosti.

Najpomembnejši faktor pri gradnji odločitvenega drevesa so metrike čistosti (*ang. purity measure, heuristic evaluation function*) za izbiro attributev. Njihova naloga je pregledati vse attribute, ki na poti do trenutnega vozlišča niso bili uporabljeni, in med njimi izbrati tistega, ki najbolj enolično

nepoznano in potencialno koristno znanje (Munoz, 2014), npr. napovedovanje nečesa na podlagi množice dejstev o tem, zbranih v preteklosti. Gre za odkrivanje vzorcev v podatkih z avtomatiziranim ali polavtomatiziranim načinom. Strojno učenje je v bistvu »trening«, torej gre za učenje računalnika. Arthur L. Samuel je leta 1959 podatkovno rudarjenje definiral kot področje učenja, ki daje računalnikom možnost, da se naučijo, ne da bi bili izrecno programirani (Munoz, 2014). Tom Mitchel je v pregledu *The Discipline of Machine Learning* (Mitchel, 2006) razlago strojnega učenja podal kot odgovor na vprašanje: »Kako lahko gradimo računalniške sisteme, ki samodejno povečujejo znanje z izkušnjami, in kaj so temeljni zakoni, ki urejajo vse učne procese?« Začetek razvoja tehnik strojnega učenja in uporabe algoritmov je povezan z J. Rossom Quinlanom (Quinlan,

1986). Med metode podatkovnega rudarjenja spadajo odločitvena drevesa, asociacijska oz. povezovalna pravila, metoda podpornih vektorjev, evolucijski algoritmi in druge.

razdeli učno množico vzorcev. Pri dobljenih podmnožicah postopek ponavljamo, dokler ne pride do enega izmed ustavitvenih pogojev, ki pomeni, da ni dovolj učnih vzorcev, da bi lahko zanesljivo nadaljevali postopek gradnje drevesa ali da vsi učni vzorci pripadajo istemu razredu, kar pomeni, da imajo isto odločitev, vsi primeri so člani istega razreda, ali da je zmanjkalo attributev, ker smo na poti do vozlišča porabili vse attribute. Ko se zgodi eden izmed ustavitvenih pogojev, vozlišče označimo za list in ga identificiramo kot razred. Ena izmed najbolj in najpogosteje uporabljenih metrik čistosti (Quinlan, 1979) je informacijski prirastek (*ang. information gain*). Iz tega izhaja izraz entropija, ki v informacijski teoriji meri nezanesljivost sporočila kot vira informacij. Čim več informacij vsebuje sporočilo, tem manjša je vrednost entropije.

Z gradnjo odločitvenih dreves je povezanih nekaj osnovnih enačb (Zorman, 2003). Na učni množici lahko opišemo naslednje verjetnosti:

$$p_{ij} = n_{ij}/n; p_i = n_i/n; p_j = n_j/n; p_{ij} = n_{ij}/n_j \quad (1)$$

Entropija E atributa A poljubnega učnega vzorca z možnimi diskretnimi vrednostmi izhodnega atributa a_1, a_2, \dots, a_m in verjetnostjo porazdelitve $p(A(w))=a_i$ je definirana kot:

$$E_A = - \sum_{j=1}^m p_j \log_2 p_j \quad (2)$$

Za izračun E_C se uporablja ista formula kot za izračun E_A , le da se verjetnost p_i nadomesti s p_i . Naj bodo $E_C, E_A, E_{C|A}$ entropija porazdelitve razredov, entropija vrednosti atributov in entropija združene porazdelitve odločitvenih razredov in vrednosti atributov:

$$E_{C|A} = - \sum_{j=1}^m \sum_{i=1}^n p_{ij} \log_2 p_{ij} \quad (3)$$

Pričakovana entropija porazdelitve razredov glede na atribut A je definirana kot:

$$E_{C|A} = E_{CA} - E_A \quad (4)$$

Informacijski prirastek je definiran kot:

$$I_{gain}(A) = E_C - E_{C|A} \quad (5)$$

V vsakem notranjem vozlišču se izbere atribut, ki doseže najvišjo vrednost I_{gain} .

Slabost informacijskega prirastka je njegov trend k uporabi atributov s čim več možnimi diskretnimi vrednostmi. Z namenom odstranitve te slabosti je Quinlan (1986) predstavil stopnjo informacijskega prirastka (ang. Information Gain Ratio), ki je definiran, kot sledi:


$$I_{gainratio}(A) = \frac{I_{gain}(A)}{E_A} \quad (6)$$

S S običajno označujemo celotno množico učnih vzorcev, opisanih z atributi A in razredi C . V predstavlja vrednost, ki jo zavzema dani atribut n , in označuje število vzorcev v učni množici; n_i je število učnih vzorcev, ki pripadajo razredu C_i , n_j označuje število učnih vzorcev, ki imajo j -to vrednost danega atributa, in n_{ij} označuje število učnih vzorcev, ki pripadajo razredu C in imajo j -to vrednost danega atributa. Postopek generiranja odločitvenega

drevesa iz učne množice imenujemo indukcija (ang. induction) odločitvenega drevesa. Pri učenju začnemo s praznim drevesom in celotno množico vzorcev. Algoritem za učenje ima dostop samo do učne množice, s katero mora ustvariti hipotezo. Če želimo preveriti možnost pravilnosti učenja, množico vzorcev S razdelimo na učno in testno množico. Razdelitev 2/3 : 1/3 je običajna. Testna množica se uporabi v namen testiranja kakovosti dobljene hipoteze in podaja predikcijsko predvideno natančnost za nevidne vzorce.

Proces gradnje odločitvenega drevesa je prikazan na sliki 2.

Cilj gradnje odločitvenega drevesa je, da krovno vozlišče učinkovito loči podatke tako, da bo drevo čim manjše. Najboljša delitev je tista, ki nam da največjo informacijsko pridobitev. Informacija ima matematični pomen, ki je povezan z gotovostjo pri odločanju.




Slika 2 • Proces gradnje odločitvenega drevesa.

3 • PODATKOVNE BAZE

Osnovno vodilo pri raziskovanju je bilo ugotoviti, ali imajo stavbe skupne elemente in ali jih lahko enoznačno določimo. Proučili smo javno dostopne podatkovne baze ((GURS, 2015), (PAM, 2015), (Emporis, 2015)) in želeli pridobiti podrobnejše podatke o konstrukcijskih elementih stavb. Ugotovili smo, da baze vsebujejo preskope podatke za nadaljnjo uporabo, zato ne moremo pridobiti podatkov o vgrajenih materialih (Stegnar, 2012). Zato je bilo treba razmisliti, kako podatke pridobiti in kako bi na podlagi znanih podatkov o stavbah (pridobljenih iz literature, arhivskih projektov, dokumentov) lahko napovedovali elemente stavb, za katere so se arhivski podatki izgubili. S tem bi na enostavnejši in hitrejši način pridobivali znanje o obstoječih stavbah in bi lahko zapolnili vrzeli tudi takrat, ko se o obstoječih stavbah ni ohranil noben zapis (načrti in

dozvoljenja za gradnjo) ((Dvornik Perhavec, 2010), (Dvornik Perhavec, 2014)). Stavba je kompleksen element, zato smo se pri delu omejili na konstrukcijski element nosilni zid, na stavbe etažnosti K+P+1+M, grajene v obdobju med letoma 1857 in 1948. Iz podatkovnih baz

znanje najhitreje pridobimo z algoritmi umetne inteligence in strojnimi učenjem. Rezultat strojnega učenja je dober toliko, kolikor sta dobra vhodni podatek in znanje tistega, ki te podatke upravlja. Ker človeški možgani ne morejo zgenerirati tolikšne množice podatkov in pridobiti vzorcev rešitev, smo nad rezultati bolj kot ne presenečeni. V primerih, ko podatkovne baze niso dovolj obsežne ali jih (še) ni, moramo model stavbe/objekta/ceste/mostu/dogodka



Slika 3 • Razstavljanje in ponovno sestavljanje stavb z namenom opisa sestavnih delov in berljivosti algoritmom umetne inteligence.

razstaviti, opisati, analizirati in ponovno sestaviti tako, da bo iz njih s strojnimi učenjem mogoče pridobiti znanje in ga posredovati uporabniku (slika 3).

Pri delu je treba uporabiti različne pristope in načine, treba je opraviti analizo projektov, analizo literature, analizo porabe toplotne energije, raziskave področij umetne inteligence s poudarkom na odkrivanju znanja v podatkih (Knowledge Discovery from Data) in podatkovnem rudarjenju (Data Mining). Podatkovno rudarjenje smo opravili z uporabo orodja Weka (akronim za: Waikato Environment for Knowledge Analysis), ki so ga zasnovali in razvili na Univerzi Waikato na Novi Zelandiji.

3.1 Podatkovne baze elementa »nosilni zid« stavb, grajenih med letoma 1857 in 1948

Na podlagi podatkov iz Stavbnega reda za vojvodino Štajersko iz leta 1857 (Deželni zakonik, 1857), zatem Stavbnega reda za vojvodino Krajnsko iz leta 1875 (Deželni zakonik, 1875) ter Zakona o graditvi objektov (Službeni list kraljevske banske uprave Dravske banovine, 1931) in Splošnih navodil za izdelavo uredbe o izvajanju regulacijskega načrta in gradbenega pravilnika (Službeni list kraljevske banske uprave Dravske banovine, 1933) smo za element zunanji nosilni zid za stanovanjske stavbe maksimalne etažnosti K+P+2 sestavili podatkovno bazo z delovnim imenom RLDB (Rules and Legislation Database). Na ta način smo dobili pravila za gradnjo zunanjih nosilnih zidov za obdobje 90 let (do leta 1948). Drugo bazo (BDB – Building Database) smo sestavili na podlagi podatkov iz načrtov za stanovanjske stavbe K+P+1, ki smo jih dobili v pokrajinskih arhivih. Na podlagi rezultatov modeliranja v Accessu smo ugotovili, da so rezultati v bazi RLDB prav enaki s podatki iz baze BDB (Dvornik Perhavec, 2014).

3.1.1 Izbira oz. vzorčenje podatkov

Vzorčenje podatkov (izbira reprezentativnih vzorcev) običajno poteka zaradi izredne velikosti podatkovnih baz, ki lahko vsebujejo milijone zapisov (npr. bančne transakcije) in jih praktično ni mogoče obdelati v celoti. Za gradnjo modela podatkovnega rudarjenja smo uporabili združeni podatkovni bazi RLDB in BDB (slika 4). Podatkovna baza je obsegala 394 vzorcev. Vsak vzorec je bil opisan z 12 atributi, od katerih je zadnji predstavljal razredni atribut.

Iz analize navedenih predpisov (Deželni zakonik, 1875, Deželni zakonik, 1857, Službeni list kraljevske banske uprave Dravske banovine, 1933) in druge literature smo dodali

Slika 4 • Vzorec podatkovne baze BDB-stavb.

	Tlačna trdnost (MPa)				
	1857	1931 (Antunović-Kobliška, 1936)		1947 (Službeni list FNRJ, 1956)	
Marka opeke za zidanje	normirana	povprečna	minimalna posamezna	povprečna	minimalna posamezna
200				20	16
150				15	12
110	8,5	11	9	11	8,5
70		7	5,5	7	5,5

Preglednica 1 • Tlačna trdnost opeke

	Odstotek vodovpojnosti (%)	Toplotna prevodnost (W/mK)
1857	15	0,58
1933	8	0,55
1947	8	0,55
beton	4	1,15

Preglednica 2 • Odstotek vodovpojnosti in toplotne prevodnosti opeke (Willems, 2006)

	Mera opeke (cm)	Število opek na m ³	Teža (kg)
do 1933	29x14x6,5	300	4–5
od 1875 do 1933	28x14x6,35	318	4–5
od 1933 ¹	25x12x6,5	400	3–4
2015	25x12x6,5	417	3

Preglednica 3 • Mere opeke (Deželni zakonik, 1857), (Deželni zakonik, 1875), (Wienerberger, 2015))

podatke o opeki in njenih karakterističnih vrednostih v različnih časovnih obdobjih (tlačna trdnost, vodovpojnost, toplotna prevodnost). Podatki so zbrani v preglednicah od 1 do 3. Podatki za leto 1857 so približni, pridobljeni na podlagi preizkušancev pri obnovi Kolizeja v Ljubljani (Kržan, 2008). Podatek o odstotku

vodovpojnosti je povprečna vrednost vodovpojnosti 16 preizkušancev, tlačna trdnost prav tako²

Za tlačno trdnost betona prevzamemo po 2 Vrednosti za tlačno trdnost so prevedene v MPa (v obravnavanem obdobju se je uporabljala enota kg/cm²).

datek 10 MPa (Antunović-Kobliška, 1936). V različnih obdobjih se je uporabljala opeka različnega formata. Mere in drugi podatki so navedeni v preglednici 3.

3.1.2 Čiščenje oz. predobdelava podatkov

Podatke je treba pripraviti za obdelavo z algoritmom za podatkovno rudarjenje, ki obsega brisanje ali zamenjavo neustreznih podatkov in pretvorbo podatkov v primeren format.

Podatkovne baze, katerih del je prikazan na slikah 2 in 3, smo zapisali v zapis strukturnega vzorca. Vzorci so opisani z lastnostmi (a_1, \dots, a_n) in razredom klasifikacije (c). Vrednosti, podane v preglednicah 1 do 3, smo preoblikovali v diskretne zapise, kot je npr. za mere opeke razvidno iz preglednice 4.

Vsak vzorec (vrstica v preglednici) je opisan z 11 atributi in razrednim atributom c , ki pove pripadajoči razred. Za iskanje karakteristik zunanjega nosilnega zidu smo oblikovali attribute, kot so zapisani v preglednici 5.

Klasifikacijski razred je sestavljen iz obdobja veljavnosti predpisa, to je od 1857–1933, 1875–1933, 1933–1948 ali letnice izdane građenega dovoljenja in območja, kjer je stavba postavljena (npr ST = Štajerska). Množico vzorcev smo preoblikovali v obliko, ki je primerna za obdelavo z algoritmi, kar je razvidno s slike 5.

3.1.3 Podatkovno rudarjenje

Za podatkovno rudarjenje smo uporabili orodje Weka, ki so ga zasnovali in razvili na Univerzi Waikato na Novi Zelandiji. Weka je zbirka orodij in algoritmov, s katerimi analiziramo podatke in modeliramo napovedovanje. Zasnovana je tako, da omogoča hitro in fleksibilno preizkušanje na novih podatkovnih nizih, in zagotavlja celostno podporo za proces podatkovnega rudarjenja, vključno s pripravo podatkov in vizualizacijo. Vsi algoritmi v Weki berejo vhodne podatke v isti obliki, v datoteki tipa ARFF (attribute – relation File Format). Programsko orodje Weka vsebuje vse standardne metode podatkovnega rudarjenja, kot so klasifikacija, regresija, gručenje podatkov, asociativnost pravil in izbiro atributov.

Iz skupka histogramov porazdelitve vzorcev za posamezne parametre vzorcev na sliki 6 razberemo, da je največ vzorcev za obdobje 1933LRS1948 (turkizno modro), sledi obdobje 1857ST1933 (rdeče) in na koncu obdobje 1875KR1933 (temno modro). Histograme sicer lahko analiziramo za vsak parameter, iz katerega je sestavljen posamezni vzorec.

	Mera opeke v cm	Oznaka velikost materiala (za modeliranje)
Do 1933	29x14x6,5	A
1875–1933 ²	28x14x6,35	B
1933	25x12x6,5	C
Kamen	ni podatka	D
Beton	ni podatka	E

Preglednica 4 • Oznaka velikost gradbenega materiala

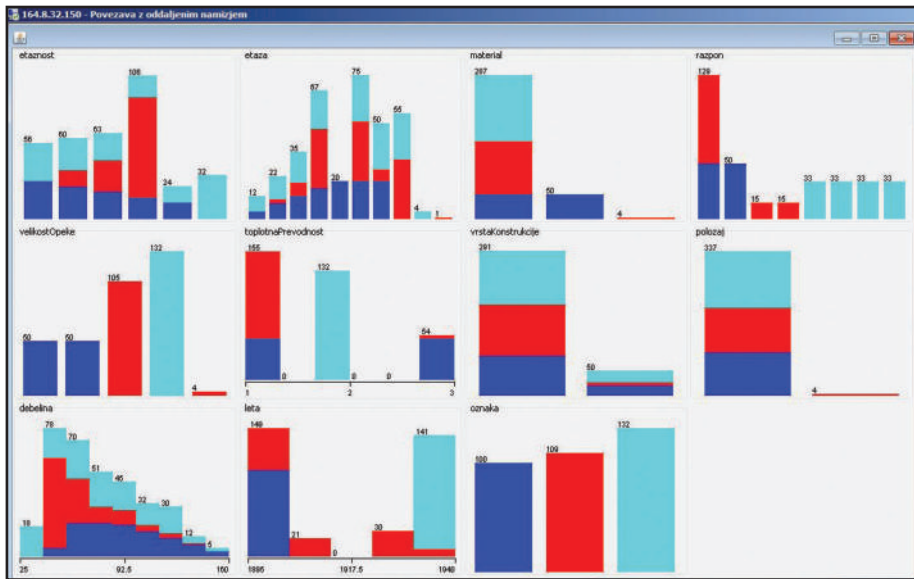
atributi	Naziv atributa	Vrednost
a_0	etažnost	KP1, KP2 ...
a_1	etaža	prva, druga ...
a_2	material	opeka, beton
a_3	razpon	a, b, c, ... , h
a_4	velikost gradbenega materiala	A, B, C, D, E
a_5	število opek na m ³ zidu	300, 400
a_6	toplotna prevodnost λ (W/mK)	1, 2 (1= 0,58, 2=0,55)
a_7	vrsta konstrukcijskega dela stavbe	nosilni zid
a_8	položaj	zunanj, notranj
a_9	debelina zidu (cm)	45, 60 ...
a_{10}	leto	1910, 1896
c	oznaka	1896ST

Preglednica 5 • Seznam atributov in klasifikacijskega razreda

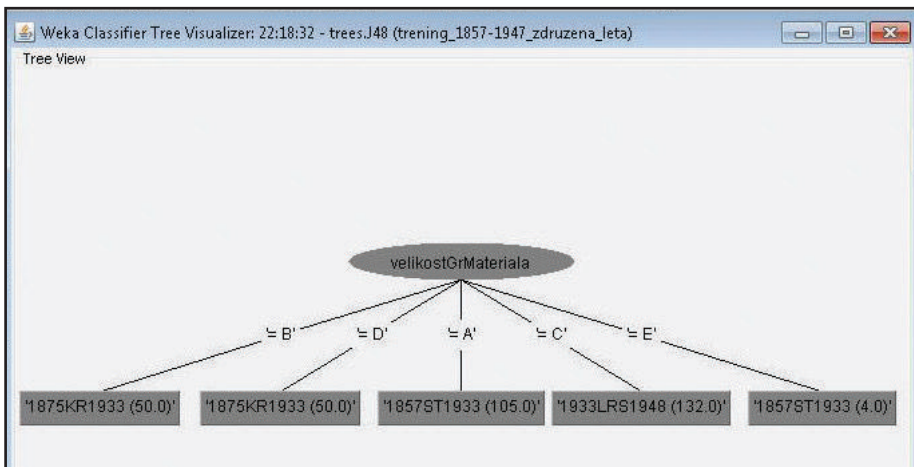
```

4.8.32.150 - Povezava z oddaljenim namizjem
KP3,DRUGA,kamen,b,D,3,nosilniZid,zunanji,85,1904,1875KR1933
KP3,PRVA,opeka,a,B,1,nosilniZid,zunanji,75,1904,1875KR1933
KP3,PRVA,kamen,a,D,3,nosilniZid,zunanji,90,1904,1875KR1933
KP3,PRVA,opeka,b,B,1,nosilniZid,zunanji,90,1904,1875KR1933
KP3,PRVA,kamen,b,D,3,nosilniZid,zunanji,100,1904,1875KR1933
KP3,PTLICJE,opeka,a,B,1,nosilniZid,zunanji,90,1904,1875KR1933
KP3,PTLICJE,kamen,a,D,3,nosilniZid,zunanji,105,1904,1875KR1933
KP3,PTLICJE,opeka,b,B,1,nosilniZid,zunanji,105,1904,1875KR1933
KP3,PTLICJE,kamen,b,D,3,nosilniZid,zunanji,115,1904,1875KR1933
KP3,KLET,opeka,a,B,1,nosilniZid,zunanji,105,1904,1875KR1933
KP3,KLET,kamen,a,D,3,nosilniZid,zunanji,120,1904,1875KR1933
KP3,KLET,opeka,b,B,1,nosilniZid,zunanji,120,1904,1875KR1933
KP3,KLET,kamen,b,D,3,nosilniZid,zunanji,130,1904,1875KR1933
KP3,TEMELJI,opeka,a,B,1,temelji,zunanji,120,1904,1875KR1933
KP3,TEMELJI,kamen,a,D,3,temelji,zunanji,135,1904,1875KR1933
KP3,TEMELJI,opeka,b,B,1,temelji,zunanji,135,1904,1875KR1933
KP3,TEMELJI,kamen,b,D,3,temelji,zunanji,145,1904,1875KR1933
KP2,DRUGA,opeka,a,B,1,nosilniZid,zunanji,45,1904,1875KR1933
KP2,DRUGA,kamen,a,D,3,nosilniZid,zunanji,60,1904,1875KR1933
KP2,DRUGA,opeka,b,B,1,nosilniZid,zunanji,60,1904,1875KR1933
KP2,DRUGA,kamen,b,D,3,nosilniZid,zunanji,70,1904,1875KR1933
KP2,PRVA,opeka,a,B,1,nosilniZid,zunanji,60,1904,1875KR1933
KP2,PRVA,kamen,a,D,3,nosilniZid,zunanji,75,1904,1875KR1933
KP2,PRVA,opeka,b,B,1,nosilniZid,zunanji,75,1904,1875KR1933
KP2,PRVA,kamen,b,D,3,nosilniZid,zunanji,85,1904,1875KR1933
KP2,PTLICJE,opeka,a,B,1,nosilniZid,zunanji,75,1904,1875KR1933
KP2,PTLICJE,kamen,a,D,3,nosilniZid,zunanji,90,1904,1875KR1933
KP2,PTLICJE,opeka,b,B,1,nosilniZid,zunanji,90,1904,1875KR1933
KP2,PTLICJE,kamen,b,D,3,nosilniZid,zunanji,100,1904,1875KR1933
KP2,KLET,opeka,a,B,1,nosilniZid,zunanji,90,1904,1875KR1933
KP2,KLET,kamen,a,D,3,nosilniZid,zunanji,105,1904,1875KR1933
KP2,KLET,opeka,b,B,1,nosilniZid,zunanji,105,1904,1875KR1933
KP2,KLET,kamen,b,D,3,nosilniZid,zunanji,115,1904,1875KR1933
KP2,TEMELJI,opeka,a,B,1,temelji,zunanji,105,1904,1875KR1933
KP2,TEMELJI,kamen,a,D,3,temelji,zunanji,120,1904,1875KR1933
KP2,TEMELJI,opeka,b,B,1,temelji,zunanji,120,1904,1875KR1933
KP2,TEMELJI,kamen,b,D,3,temelji,zunanji,130,1904,1875KR1933
KP1,PRVA,opeka,a,B,1,nosilniZid,zunanji,45,1904,1875KR1933
KP1,PRVA,kamen,a,D,3,nosilniZid,zunanji,60,1904,1875KR1933
KP1,PRVA,opeka,b,B,1,nosilniZid,zunanji,60,1904,1875KR1933
KP1,PRVA,kamen,b,D,3,nosilniZid,zunanji,70,1904,1875KR1933
KP1,PTLICJE,opeka,a,B,1,nosilniZid,zunanji,60,1904,1875KR1933
KP1,PTLICJE,kamen,a,D,3,nosilniZid,zunanji,75,1904,1875KR1933
KP1,PTLICJE,opeka,b,B,1,nosilniZid,zunanji,75,1904,1875KR1933
KP1,PTLICJE,kamen,b,D,3,nosilniZid,zunanji,85,1904,1875KR1933
    
```

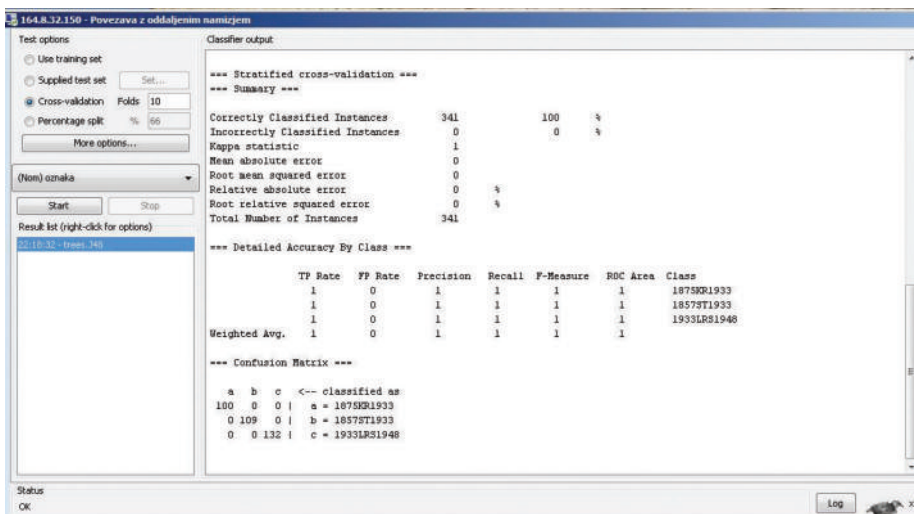
Slika 5 • Množice vzorcev.



Slika 6 • Skupek histogramov glede na vzorce in posamezne parametre (atribute).



Slika 7 • Odločitveno drevo.



Slika 8 • Evalvacija klasifikatorjev.

Rezultati po opravljeni gradnji odločitvenega drevesa so prikazani na sliki 7.

Kvaliteto klasifikatorja najpogosteje merimo na osnovi nekaterih indikatorjev, kot so natančnost, senzitivnost in specifičnost, grafični prikaz pravilno klasificiranih pozitivnih vzorcev proti napačno klasificiranim pozitivnim vzorcem za družino klasifikatorjev (krivulja ROC) in različne metode za delitev baze podatkov na učno in testno množico. Množica vzorcev je sestavljena iz dveh podatkovnih baz RLDB in BDB, zato smo pričakovali okoli 80-% pravilnost klasificiranja v posamezne razrede. V praksi namreč ni pričakovati, da bi se konstrukcijska pravila obdržala celotno obdobje trajanja določenega predpisa in da so se pravila grajenja dosledno upoštevala v praksi. Ob 341 vzorcih z 10 različnimi atributi je natančnost klasifikatorja dosegla 100-% pravilnost vzorca, kar je razvidno s slike 8.

3.1.4 Cenitev in predstavitev rezultatov

Rezultate kot posledice klasifikacije moramo v zaključni fazi ovrednotiti. S tem se ugotovi dejanska kakovost dobljenih rezultatov in posredno kakovost uporabljenih algoritmov. Z upoštevanjem konstrukcijskih pravil in karakteristik obstoječih stavb ugotovimo, da so rezultati z uporabo metod umetne inteligence na majhnem vzorcu nadpovprečni.

Predstavitev rezultatov je namenjena prireditvi rezultatov obdelave v obliko, prirejeno končnemu uporabniku. S tem približamo informacije uporabniku tako, da razume, kako informacije, ki jih je mogoče enostavno razumeti, postanejo zanj uporabno znanje. Največji informacijski prirastek predstavlja atribut velikostGrMateriala, ki je razviden s slike 7. Na podlagi tega atributa zanesljivo in z gotovostjo uvrstimo stavbo v primerno časovno obdobje in mu določimo preostale karakteristike, kot so podatki o opeki, debelina nosilnega zidu za posamezno vrsto stavbe in etažo in podobno. Znanje, ki je skrito v informacijah, nazorno kaže, da se je beton na Štajerskem začel uporabljati pred letom 1940, kar je prikazano na sliki 9.

Če želimo preveriti, v katerem delu stavbe je beton, izberemo drugo kombinacijo atributov (material, etaža) in na podlagi rezultata ugotovimo, da je beton v kletnih zidovih, kar je razvidno s slike 10. Dobljene rezultate smo preverili na terenu pri poljubnih stavbah etažnosti K+P+1+M v Mariboru.

3.2 Podatkovne baze karakteristike »poraba

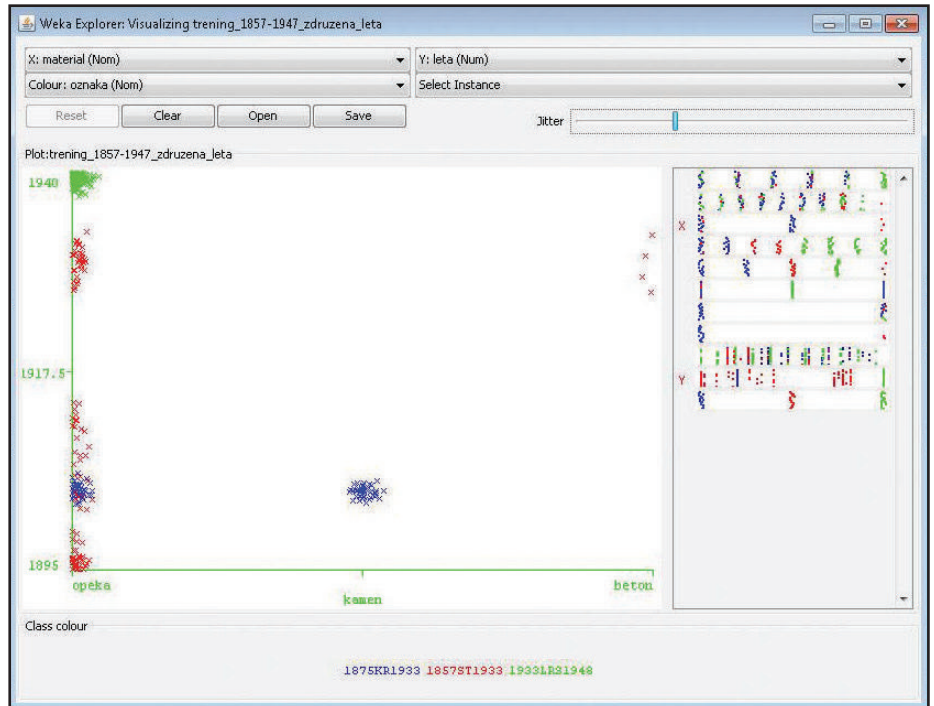
toplotne energije» za stavbe tehniških fakultet

Sklop tehniških Fakultet Univerze v Mariboru obsega 12 med seboj povezanih stavb, grajenih v obdobju 1964–2006. Podatkovno bazo smo oblikovali na podlagi načrtov, arhiviranih v prostorih tehniških fakultet. V prvi fazi smo s skupnimi značilnostmi opisali stavbi J1 in J2, pozneje smo dodali značilnosti še za druge stavbe.

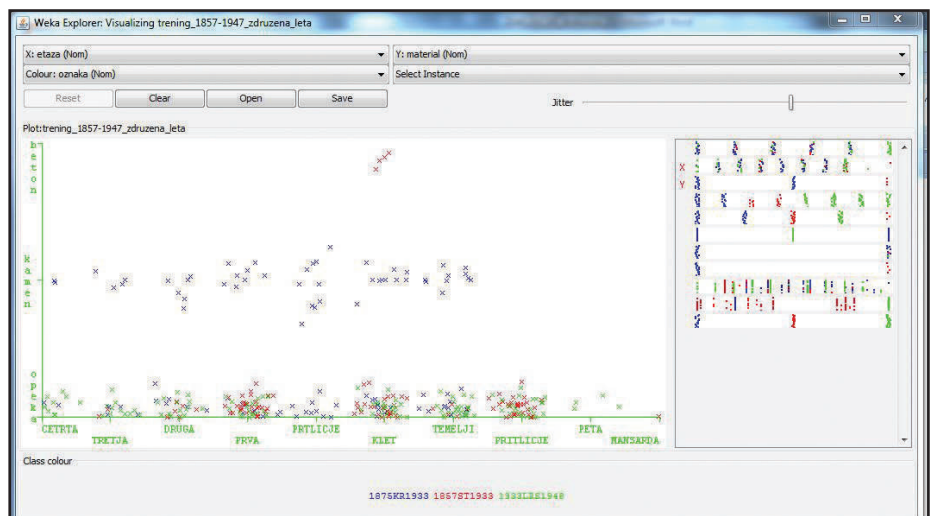
Za arhitekturno zasnovo in tipologijo stavb smo upoštevali tipologijo stavb Tabula (Gradbeni inštitut ZRMK, d. o. o, 2009–2012) in podatke o ovojju stavbe. Podatke o porabi toplotne energije stavb na območju tehniških fakultet smo za obdobje od leta 2012 do decembra 2016 pridobili od dobavitelja ELTEC Petrola, d. o. o. Podatki so zbrani po posameznih toplotnih podpostajah tabelarično in grafično z navedbo porabe toplotne energije posamezne toplotne podpostaje (TOP 809, TOP 808 in TOP 807). Količina toplotne energije za TOP 809, ki je namenjena za ogrevanje stavb J1 in J2, je prikazana v preglednici 6. Poraba toplotne energije za stavbi J1 in J2 po mesecih in letih je razvidna s slike 12.

3.2.1 Podatkovno rudarjenje po elementih skupnih značilnosti stavb z razdeljeno porabo toplotne energije – vse stavbe


Postopek, naveden v poglavju 3.1.3, smo ponovili na podatkovni bazi za stavbe tehniških fakultet s tem, da smo porabo toplotne energije upoštevali za celo leto 2014 in jo razdelili glede na delež skupne tlorisne površine posamezne stavbe. Podatkov o porabi toplotne energije za posamezno stavbo namreč ni na razpolago. V odvisnosti od porabe toplotne energije na m² površine smo v skladu s Pravilnikom o metodologiji izdelave in izdaje energetskih izkaznic stavb (Uradni list RS, 2014) določili energetske razrede. Vzorec smo opisali z naslednjimi atributi: tip fasade, tlorisna površina stavbe, volumen, površina fasade glede na smer neba (sever, jug, vzhod, zahod), površina odprtih glede na smer neba (sever, jug, vzhod, zahod), leto gradnje in odločitveni atribut oznaka stavbe (J1, B, C ...). Del podatkov je razviden iz preglednice 7. Podobno kot vrednosti, navedene v preglednicah 1–3, smo vrednosti za ogrevalno površino in porabo toplotne energije preoblikovali v diskretne zapise. Pri tem smo diskretizacijsko oznako prilagodili energetskim razredom, kot je razvidno iz preglednice 8.



Slika 9 • Znanje, ki je skrito v informacijah; pojavnost betona v obstoječih




Slika 10 • Znanje, skrito v informacijah; beton v kletni etaži.



Slika 11 • Pogled na stavbo J1 (levo) in stavbo B (desno). (Fotografija: Daniela Dvornik Perhavec)

Št.	Šifra toplotne postaje	Odjemno mesto	obstoječa / nova (toplotna postaja)	Naziv članice Univerze v Mariboru	Obračunska moč [kW]	količina [MWh]								
						Januar	Februar	Marec	April	Maj	Oktober	November	December	
3.	TOP809	TF - J1	nova	Fakulteta za elektrotehniko, računalništvo in informatiko, Smetanova 17, 2000 Maribor	560	2012	103,76	113,20	61,43	35,45	0,55	41,67	53,60	74,16
						2013	101,58	84,18	70,88	21,14	0,00	17,15	48,79	75,26
						2014	66,45	62,78	36,38	17,43	0,00	16,84	36,91	75,79
						2015	77,24	71,87	50,38	26,39	1,47	26,93	41,78	69,63
						2016	73,26	52,27	50,9	19,09	0,9	27,44	52,35	77,47

Preglednica 6 • Količina toplotne energije toplotne podpostaje TOP 809



Slika 12 • Grafični prikaz porabe toplotne energije v TOP 809 po letih in mesecih.

Tip Fasade	Površina [m ²]	Volumen [m ³]	Fasada sever [m ²]	Steklene površine sever [m ²]	Fasada jug [m ²]	Steklene površine jug [m ²]	Fasada vzhod [m ²]	Steklene površine vzhod [m ²]	Fasada zahod [m ²]	Steklene površine zahod [m ²]	Leto gradnje [leto]	Stavba [oznaka]
fasadna opeka	496,64	10218,35	623,07	379,44	623,07	368,72	0	0	339,48	41,4	1983	J1
fasadna opeka	633,92	13122,14	585,81	280,08	585,81	345,44	463,68	0	0	0	1986	J2
teranova	798,06	13814,45	979,05	276	979,05	598,5	81,42	0	0	26,7	1964	A
teranova	851,243	14735,02	814,09	306,18	814,09	291,41	104,44	8,645	104,44	47,25	1964	B
teranova	577,88	4727,1	164,33	10	0	0	226,18	103,25	226,18	127,19	1964	C
ne	798,06	3295,99	233,59	31,36	233,59	39,2	19,42	0	0	7,875	1980	A+
ne	851,243	4145,55	229,04	29,4	229,04	23,52	29,38	0	29,38	0	1980	B+
fasadna opeka	606	10362,58	625	362,34	625	374,82	0	0	0	0	1969	D1
fasadna opeka	207,25	3543,97	213,75	141,856	213,75	139,276	283,52	60,78	0	0	1990	D2
teranova	2000,5	11294,1	193,79	103,11	0	0	65,74	7,04	0	0	1969	E
teranova	645,17	5445,24	0	0	0	0	169,48	113,875	0	77,875	1969	F
teranova	501,75	8710,38	195,3	186,774	390,6	239,91	0	0	0	0	1981	G1
teranova	385,86	5012,4	198,75	111,01	198,75	198,75	0	0	0	0	2006	G1+
fasadna opeka	542,66	5030,49	0	0	0	0	0	0	0	0	1982	H

Preglednica 7 • Množica vzorcev

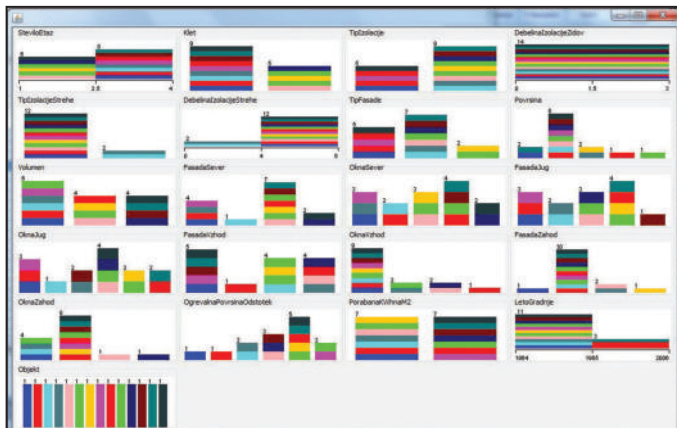
Na sliki 13 je razviden skupek histogramov za učno množico. Po opravljenem učenju smo dobili rezultate klasifikacije, kot je razvidno iz odločitvenega drevesa na sliki 14.

Rezultati za primer, ki smo ga obravnavali, kažejo, da največji informacijski prirastek predstavlja tip fasade, nadalje pa bi na podlagi volumna stavbe posamezno stavbo lahko

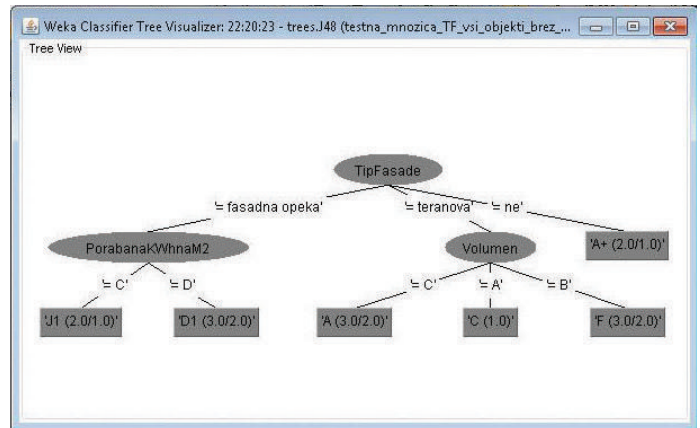
uvrščali v posamezne energetske razrede. Ker gre za eksperiment, bo za natančnejše napovedi treba dopolniti baze tako vsebinsko kot količinsko.

Celotna ogrevalna površina	Odstotek površine	Razred diskretizacije	oznaka	Poraba 2014MWh	Poraba 2014KWh na m ² površine	Razred diskretizacije	Diskretizacijska oznaka ³
2483,2	44	41-50	e	137,54	55,38821	35-60	C
3169,6	56	51-60	f	175,06	55,23094	35-60	C
3404,972	36	31-40	d	176,1	51,71849	35-60	C
1155,76	12	11-20	b	58,71	50,79774	35-60	C
851,243	9	0-10	a	44,02	51,71261	35-60	C
3030	24	21-30	c	258,6	85,34653	60-105	D
1036,25	8	0-10	a	86,2	83,18456	60-105	D
2508,75	19	11-20	b	204,72	81,60239	60-105	D
1929,3	15	0-10	a	161,63	83,7765	60-105	D

Preglednica 7 • Množica vzorcev



Slika 13 • Skupek histogramov glede na vzorce in posamezne atribute.



Slika 14 • Rezultati klasifikacije v obliki odločitvenega drevesa.

4 • SKLEP

Iskanje korelacij med vsebinsko različnimi zadevami je s podatkovnim rudarjenjem smiselno, če imamo podlago v obširnih bazah. V raziskavi smo eksperimentirali s podatki, ki se nanašajo na karakteristične elemente stavbe kot tudi v kombinaciji s porabo toplotne energije. Dobljeni rezultati prvega modela kažejo, da velikost opeke kot del nosilnega zidu poda največ informacij in da lahko na podlagi tega stavbe pravilno uvrstimo v geografsko in časovno obdobje ter določimo karakteristike nosilnega zidu po različnih etažah. Na podlagi narejenih analiz in rezultatov ugotovimo, da imajo stavbe, grajene v določenem časovnem obdobju, skupne imenovalce in da na podlagi dobljenih rezultatov lahko napovedujemo skupne značilnosti obstoječih stavb. Na osnovi uporabe algoritmov umetne inteligence pridemo do novo odkritega znanja, v fazi analize obstoječe stavbe pa imamo možnost, da s tehnologijami upravljanja znanja to znanje tudi

uporabimo. Posledično to pomeni, da lahko zmanjšamo čas in stroške faze raziskovanja stavb in povečamo determiniranost celotnega projekta prenove (Dvornik Perhavec, 2014) kot tudi upravljanja. Pri drugem modelu so odločilni tip fasade ter nadalje volumen stavb in poraba toplotne energije. Nadaljnja raziskovanja v tej smeri pomenijo, da s spremljanjem porabe toplotne energije, zasedenosti stavbe, notranjih in zunanjih temperatur lahko pridobivamo nova spoznanja o možnosti prihrankov energije z izboljšanim energetske upravljanjem (Dvornik Perhavec, 2016). Rezultat eksperimenta, opisanega v poglavju 3.2, je nastal na podlagi sodelovanja pri razvojnoraziskovalnem projektu E-nepremična inženirska zakladnica. Projekt je sicer zasnovan na dolgoročnem sodelovanju deležnikov iz gospodarstva in okolja.

Ob dejstvu, da se področja umetne inteligence vse bolj razvijajo in da je npr. na Univerzi Stan-

ford 90 % vseh dodiplomskih študentov izbralo in poslušalo že leta 2013 vsaj en računalniški predmet (Žerdin, 2013), je vprašanje, ali bomo temu sledili tudi na področju gradbeništva in grajenega okolja, povsem odveč. Z razvojem tehnologij BIM bomo s časom podatkovne baze o stavbah pridobili. Razmisliti bo treba, kako upravljati podatke in jih arhivirati z namenom zagotavljanja dostopnosti in varnosti, saj se bodo istočasno razvijali novi poklici, npr. podatkovni upravljalci, ki bodo v času obstoja obstoječih objektov podatke upravljali v različne interdisciplinarnе namene. Vendar pri tem ne gre le za stavbe, saj lahko podobno upravljamo podatkovne baze drugih inženirskih in infrastrukturnih objektov. Eksperimenti so bili narejeni za kombinacijo podatkov podatkovnih baz cestne infrastrukture in pogostosti prometnih nesreč (Dvornik Perhavec, 2016) ter podatkov iz podatkovnih baz monitoringa ogrevanja in zasedenosti vrtcev (Praper, 2016).

5 Oznaka ustreza oznakam energetskih razredov.

5 • ZAHVALA

Zahvaljujemo se podjetjema Energetika Maribor, d. o. o., in EUTRIP, d. o. o., za zaupanje in izkazan interes pri podpori raziskovalnemu delu.

6 • LITERATURA

- Antunović-Kobliška, M., Cigola, S. A., Poznavanje građevinskog materijala udžbenik i priručnik. Beograd, 1936.
- Deželni zakonik, Stavbni red za Štajersko, Gradec, 1857.
- Deželni zakonik, Stavbni red za Vojvodino Kranjsko, Ljubljana, 1875.
- Dvornik Perhavec, D., Conservation of cultural heritage – disorders, deficiencies and building project, Žabljak: Faculty of Civil Engineering, University of Montenegro, 2010.
- Dvornik Perhavec, D., Databases and Data Warehouses in a Systemic Approach for Historical Building Reconstruction Projects, Civil Prompt Proceedings Napoly, 2014.
- Dvornik Perhavec, D., E-Nepremična inženirska zakladnica, Tehniške fakultete, Fakulteta za gradbeništvo, prometno inženirstvo in arhitekturo Univerze v Mariboru, 2015.
- Dvornik Perhavec, D., Kataster gospodarske javne infrastrukture kot osnova za modeliranje s podatki, Portorož, DRC, Družba za raziskave v cestni in prometni stroki Slovenije, str. 1–9, 2016.
- Dvornik Perhavec, D., Rebolj, D., Praper, P., Pridobivanje informacij iz razpoložljivih podatkov o stavbah z uporabo metod umetne inteligence, Ljubljana, 2016.
- Dvornik Perhavec, D., Rebolj, D., Šuman, N., Journal of cultural heritage. Systematic approach for sustainable conservation, 17. februar 2014.
- Dvornik Perhavec, D., Tibaut, A., Journal of Civil Engineering and Architecture Research, Databases in the Process of Maintenance and Reconstruction Projects of Existing Buildings, 25. oktober, str. 251–259, 2014.
- Emporis, <https://www.emporis.com/>, 2015.
- Gams, M., Alan M. Turing, Izumitelj univerzalnega stroja, 1912–1954 in 2012, http://home.izum.si/cobiss/oz/2012_2/html/clanek_00.html, 2012.
- GURS, Geodetska uprava Republike Slovenije, Register nepremičnin, Ljubljana, 2015.
- GI ZRMK, Gradbeni inštitut ZRMK, d. o. o., IEE Tabula, številka pogodbe IEE/08/495/SI2.528393, Narodna in univerzitetna knjižnica, Ljubljana, 2009–2012.
- Han, J., Kamber, M., Data Mining Concepts and Techniques, Elsevier, 2006.
- Kržan, M., Parametrična analiza potresne odpornosti Kolizeja v Ljubljani, http://drugg.fgg.uni-lj.si/570/1/GRU_3028_Krzan.pdf, 2008.
- Mitchel, T. M., The Discipline of Machine Learning, <http://www.cs.cmu.edu/~tom/pubs/machinelearning.pdf>, 2006.
- Munoz, A., Machine Learning and Optimization, https://www.cims.nyu.edu/~munoz/files/ml_optimization.pdf, 2014.
- Oteiza, J., <http://smardatacollective.com/josueoteiza/38043/difference-between-knowledge-discovery-and-data-mining>, 2011.
- PA Maribor, Pokrajinski arhiv Maribor, Republika Slovenija, Ministrstvo za kulturo RS, Maribor, 2015.
- Praper, P., Integrirani monitoring kot orodje za učinkovito in ekonomično energetska upravljanje javnih stavb, magistrska naloga, Univerza v Mariboru, Maribor, 2016.
- Pravilnik o metodologiji izdelave in izdaje energetskih izkaznic stavb, Uradni list RS 92/2014, 2014.
- Quinlan, J., Discovering Rules by Introduction from Large Collections of Examples, Expert Systems in the Microelectronic Age, 1979.
- Quinlan, J., Introduction of decision tree, Machine learning, Zvezek 1, 1986.
- Russell, S., Norvig, P., Artificial Intelligence, A modern Approach, Prentice Hall, 2004.
- Sistory, Službeni list Kraljevske banske uprave Dravske banovine za leto 1932, 1. polletje, <http://www.sistory.si/publikacije/prenos/?Urn=SISTORY:ID:185#page=100>, 1932.
- Službeni list FNRJ, Uredba o privremenim normama i privremenim tehničkim propisima u građevinarstvu, 18. april 1947, ured. Građevinska knjiga, Beograd, 1956.
- Službeni list Kraljevske banske uprave Dravske banovine, letnik II, št. 47, 13. Avgusta 1931, Ljubljana, 1931.
- Službeni list Kraljevske banske uprave Dravske banovine, Splošna navodila za izdelavo uredbe o izvajanju regulacijskega načrta in gradbenega pravilnika, Ljubljana, 1933.
- Stegnar, G., Šijanec Zavrl, M., Stankovski, V., Uporaba informacijskih virov pri tipizaciji stavb v Sloveniji, Gradbeni vestnik, zvezek 61, str. 256–262, november 2012.
- Wienerberger, Tehnični list, Ormož, 2015.
- Willems, W. M., Schild, K., Dinter Vieweg, S., Handbuch Bauphysik, Teil 1, Springer, 2006.
- Witten, I. H. & Frank, E., Data Mining, Second edition, Elsevier, San Francisco, 2005.
- Zorman, M., V. Podgorelec, V., Lenič, M., Povalej, P., Kokol, P., Tapajner, A., Inteligentni sistemi in profesionalni vsakdan, Center za interdisciplinarne in multidisciplinarne raziskave in študije Univerze v Mariboru, Maribor, 2003.
- Žerdin, D., dr. Jure Leskovec, Dnevnik, <https://www.dnevnik.si/1042576652>, 2013.