

Predviđanje revizorskog mišljenja primenom plitke i duboke neuronske mreže podržane veštačkom inteligencijom (ChatGPT)

Apstrakt: *Ubrzana primena veštačke inteligencije (VI) u svim domenu ljudske delatnosti, nije zaobišla ni revizorske poslove. U domenu primene VI u reviziji postavlja se suštinsko pitanje da li je potrebno da se revizorskog mišljenja obavi sa plitkim ili obimnim podacima. Metode VI nam pružaju mogućnost predviđanja (na bazi primera radi racio pokazatelja) da na oskudnim-plitkim podacima dođemo do preciznih rezultata. Autor je napravio paralelu tačnosti između klasičnih metoda mašinskog učenja i dubokog učenja podržanog Chat GPT. I tu se vide prednosti primene AI. Naravno, veći broj raspoloživih podataka povećao bi tačnost predviđanja, što je predmet daljih istraživanja. Budućnost leži u kombinaciji ljudskog poimanja računovodstva i revizije i sirovih podataka, koji kriju implicitna znanja.*

Ključne reči: *predviđanje revizorskog mišljenja, mašinsko učenje, duboko učenje, ChatGPT.*

¹ EFR doo, Beograd, Srbija.
E-mail: efr_vracar@yahoo.com
ORCID iD: <https://orcid.org/0009-0002-2034-8592>

UVOD

Za početak da se osvrnemo na neke metodološke manjkavosti dosadašnje revizorske prakse na jednom konkretnom primeru., kako sledi:

Respektibilna revizorska firma, koja primenjuje sopstvenu metodologiju revizije, obelodanila je nakon finaliziranja revizije privednog društva (revizijskog klijenta) revizorsko mišljenje. Opreza radi a respektujući elementarni etički kodeks ove struke, kao i Zakona o računovodstvu i reviziji[3], daćemo sublimirani prikaz ovo mišljenje u generalno neprepoznatljivoj formi.

Preduzeće „XYZ” je izvršilo reviziju za 20XX godinu. Prikaz mišljenja nezavisnog revizora se može sublimirati na ograde koje se svode na to: da je pogrešno proknjiženo zemljište, analitika kupaca i analitika dobavljača. Saobrazno Međunarodnim standardima revizije (MSR)², revizorsko društvo je ispravno, dalo mišljenje sa rezervom na napred pomenute okolnosti.

Naknadnim i nezavisnim ispitivanjem od strane inostranih eksperata, koji su hteli da kupe ovu firmu, potvrđena su načelno mišljenja ove revizorske kuće, ali takođe je utvrđeno da revizori ove firme nisu otkrili, da ova firma ima skrivene gubitke na zalihama i da je njihov bilans koji obelodanjuje dobitak ustvari realno u gubitku, reda veličine više desetina miliona evra.

Ono što je od sušastvenog značaja za našu analizu jeste da dosadašnja praksa signalizira neadekvatnost metodološkog aparata revizije. Ovaj slučaj nam je poslužio da pokušamo da ukažemo na mogućnost primene metodološkog aparata mašinskog učenja koje se u stručnom smislu naziva pronalaženje skrivenih znanja (Data Mining)³, što je predmet narednih razmatanja, polazeći od definisanja skupa podataka o revizorskim mišljenjima.

DEFINISANJE PODATAKA O REVIZORSKIM MIŠLJENJIMA

Induktivno učenje se vrši tako da se model problema kreira tako da uključuje sve raspoložive informacije o nekoj pojavi, a obučavajući skup se formira na osnovu konačnog broja poznatih ili razmatranih slučajeva ili instanci. Primeri problema sa velikim brojem atributa (u našem slučaju racio pokazatelja⁴) i veoma malim brojem primera (mali broj obveznika revizije). Oskudni podaci (sparse data) se definišu kao slučaj kada obučavajući skup predstavlja veoma mali podskup prostora primera. To su podaci kod kojih je odnos broja opservacija (primera) i broja promenljivih (atributa) mali. Skup podataka je oskudan ako većina tačaka iz prostora atributa nije zastupljena u primerima, tj. skup u kojem se javlja problem nedostatka relevantnih, odnosno suštinskih pozitivnih primera.

² Revizorske firme ugrađuju Međunarodne standarde revizije u metodologiju revizije, obogaćujući je sa upitnicima i drugim tehničkim pomagalicima.

³ Neki je nazivaju implicitna znanja.

⁴ Broj atributa može biti značajno veliki 1000, 2000,

Tačnost predviđanja ne treba da bude suviše visoka nakon uvida u samo mali broj primera iz obučavajućeg skupa. Veličina prostora primera, koja je domena atributa, tipično je više redova veličine veće od prostora primera. Ovaj odnos se može smanjiti ograničavanjem broja atributa, tako da podaci više nisu oskudni (plitki). Primera radi neki skupovi sa samo 100 obučavajućih primera opisanih sa 10.000 atributa svrstani u bogate, dok su skupovi sa 300-800 primera sa 2.000-3.000 atributa označeni kao oskudni. Kriterijum oskudnosti je povezan sa procenom težine problema učenja (task difficulty). U teoriji mašinskog učenja (8) razmatra se problem nalaženja konzistentne hipoteze u prostoru svih mogućih hipoteza (konzistentna hipoteza je saglasna sa svakim primerom iz obučavajućeg skupa, a algoritam koji nalazi konzistentne hipoteze je konzistentan algoritam). U principu ovom radu će se usvojiti definiciju oskudnosti obučavajućeg skupa, koja se zasniva na tačnosti predviđanja naučenog znanja.

Uspešnost razlikovanja novih primera zavisi od konkretnog problema i određuje se empirijski. Npr. u medicini je potrebno postići istu ili veću tačnost predviđanja od lekara-specijalista, što je veoma subjektivna ocena, koja se razvojem medicine menja. Estimacija tačnosti naučenog znanja veoma zavisi i od metoda estimacije. U ovom radu se koristi metod unakrsne validacije, koji se smatra "skoro objektivnim". Kada se koriste metodi selekcije atributa, vrši se "dvostruka krosvalidacija", odnosno krosvalidacija rezultata algoritma učenja se vrši unutar jednog krosvalidacionog koraka selekcije atributa. U se navode dva osnovna razloga oskudnosti obučavajućeg skupa: (1) nedovoljan broj primera za učenje i (2) prevelika složenost razmatranog problema. U takvom slučaju su i uobičajene pretpostavke postojećih metoda pojednostavljivanja naučenog znanja neodgovarajuće i one same imaju negativne posledice na tačnost predviđanja naučenog znanja. (7)

Definicija obučavajućeg skupa glasi: "Obučavajući skup je oskudan (sparse) ako induktivno naučeno znanje ne omogućava dovoljno uspešno razlikovanje novih primera."

PRONALAZENJE SKRIVENIH ZNANJA U POSTUPKU OBAVLJANJA REVIZIJE

U narednom delu priloga ćemo taksativno navesti suštinske elemente istraživanje podataka putem metoda pronalaženja skrivenog znanja (*data mining-DM*), bez ulaženja u formalno-algoritamsku analizu, što nije predmet našeg razmatranja, posebno jer se radi o revizorima i računovodstvenim ekspertima, koji ipak trebaju da znaju da primene i interpretiraju dobijene rezultate.

Data mining obuhvata primenu metoda mašinskog učenja i drugih metoda, za pronalaženje uzoraka u razmatranim podacima.

U tom smislu potrebno je razlikovati induktivno učenje uz pomoć „učitelja“ (*nadzirano učenje*) tj. učenje koje se vrši na osnovu klasifikovanih primera, odnosno donesenih odluka.

Induktivno učenje koncepata je forma mašinskog učenja čiji je cilj indukcija takvih opisa koncepata (kategorija, klasa objekata), koji su razumljivi ljudima koji se bave

određenom problematikom, odnosno koji odgovaraju konceptima koje bi proizveo čovek prilikom razmatranja istih entiteta.

Produkciona pravila, liste odlučivanja i stabla odlučivanja su primeri razumljivog načina predstavljanja empirijskog znanja.

Metode induktivnog učenja koncepata se koriste u istraživanju podataka jer daju razumljive rezultate, koji se mogu direktno interpretirati. Tačnost predviđanja ovih metoda takođe visoka i može se uporediti sa najuspešnijim metodama induktivnog učenja.

Primer koji smo izabrali za ilustraciju ovog pitanja odnosi se na svega 48 preduzeća sa 19 atributa, što znači da se radi o oskudnom skupu (plitkom).

KLASIČNI PRISTUP PRIMENI MAŠINSKOG UČENJA⁵

Metoda mašinskog (data mining) učenja (decision tree) stablo odlučivanja su najpopularnija struktura za DM sa nadgledanjem. glavni cilj je da se minimizuje broj nivoa u stablu i broj čvorova u stablu, maksimizujući generalizaciju podataka. stabla odlučivanja koja su uspešno primenjena na realne probleme su laka za razumevanje i lako se primenjuju na skup produkcionih pravila.

Stablo odlučivanja (*decision tree*) (5) je, kako smo napomenuli popularna struktura za učenje sa nadgledanjem. stablo odlučivanja se kreira samo od onih atributa koju najbolje opisuju koncept koji se uči. stablo odlučivanja se inicijalno kreira izborom podskupa instanci iz obučavajućeg skupa. Ovaj podskup se onda koristi od strane algoritma radi konstruisanja stabla odlučivanja. preostali trening set testira tačnost konstruisanog stabla. ukoliko stablo odlučivanja klasifikuje korektno instance, tu se procedura završava. ukoliko je neka instanca loše klasifikovana, dodaje se izabranom podskupu tening instanci i novo stablo se kreira. ovaj proces se ponavlja sve dok se ne kreira stablo koje dobro klasifikuje sve instance koje nisu izabrane ili dok se stablo odlučivanja ne kreira od celog trening seta. Ako bi uzeli pojednostavljenju strukturu algoritma koji uzima u obzir ceo trening set za izgradnju stabla odlučivanja, koraci tog algoritma bi bili sledeći:

- (1) neka je t skup trening instanci.
- (2) biramo jedan atribut koji najbolje razlikuje instance sadržane u t .
- (3) kreiramo čvor stabla čija je vrednost izabrani atribut. kreiramo linkove dece od ovog čvora gde svaki link predstavlja jedinstvenu vrednost za izabrani atribut. Vrednosti tih linkova dece se koriste za dalje deljenje instanci u podklase.

⁵ Za potrebe naše analize imali smo u vidu sledeće tehnike, i to:

- da je učenje sa nadgledanjem.
- da zahtevamo jasno objašnjenje o odnosima koji postoje u podacima.
- da li postoji jedan set ulaznih atributa i jedan izlaznih atributa,
- da su podaci kombinacija numeričke, i kategorijske forme.
- učenje je nadgledano, postoji jedan izlazni atribut i oni su kategorijski.

- (4) za svaku podklasu kreiranu u koraku 3:
- (5) ako instance u podklasi zadovoljavaju predefinisani kriterijum ili je set preostalih izbora atributa za ovu stranu drveta prazan, specifikuje se klasifikacija za nove instance praćenjem ove strane odlučivanja.
- (6) ako podklasa ne zadovoljava predefinisani kriterijum i postoji makar jedan atribut za dalje deljenje ove strane drveta, onda je t tekući set podklasi instanci i vraćamo se na korak 2.

Osnovni cilj je da se minimizije broj čvorova, a na taj način i maksimizuje generalizacija podataka. Algoritam c4.5 (jedan od poznatih algoritama mašinskog učenja za kreiranje stabla odlučivanja u postupku kvalifikacije) koristi mere preuzete iz informacione teorije, da bi se olakšao proces selekcije atributa. Osnovna ideja je da na bilo kojoj tački odlučivanja u stablu, c4.5 bira atribut koji razdvaja podatke tako da prikaze najveći obim dobijenih informacija.

Stablo odlučivanja predstavlja strukturu gde lišće (čvorovi) predstavljaju klasifikacije i grane predstavljaju združavanje osobina koje vode do tih klasifikacija (5).

Primenićemo Weka system (6), koji je razvijen na Univerzitetu Waikato na Novom Zelandu⁶. Sistem je napisan u JAVI programskom jeziku, koji omogućava kreiranje uniformnih interfejsa za dosta algoritama učenja, za metode pre i posle procesiranja podataka, kao i za merenje rezultata učenja na svim primenjenim skupovima podataka(1; 4; 3; 8).

STABLO ODLUČIVANJA

U prilogu je primenjen tip *klasifikaciona stabla* (classification tree), ovaj termin koristimo kada je predviđeni izlaz klasa kojoj pripadaju podaci, koji su dati u prilogu rada, i to za date racio pokazatelje, koji su dati prilogu sa respektivnim mišljenja revizora za revizorskih društava. Posebno treba napomenuti da je mišljenje revizora dato u dva varijeteta: pozitivno i nije pozitivno (znači: nekvalifikovano, i kvalifikovano). Takođe treba dati naglasak da se radi o oskudnom odnosno plitkom uzorku, koji po definiciji nedaje dobre rezultate, ali je važno videti koliko je i u tim sulovima koristan.

Kreiraćemo *stablo odlučivanja* (*Decision Tree*), primenom algoritma J48 (5), koji je ustvari klasa u WEKA sistemu koja kreira model stabla odlučivanja. Test opcije su da koristimo krosvalidaciju, a atribut u odnosu na koji kreiramo stablo je racio pokazatelj, koji najviše utiče na mišljenje revizora (10; 3).

Ova datoteka, bazirana na podacima iz APR-a, ima 48 primera (preduzeća) sa ukupno 19 atributa (uključujući mišljenje revizora) uz napomenu da smo sveli mišljenje samo

⁶ Waikato Environment for Knowledge Analysis (Weka) is a collection of machine learning and data analysis free software licensed under the GNU General Public License. It was developed at the University of Waikato, New Zealand and is the companion software to the book "Data Mining: Practical Machine Learning Tools and Techniques"

na kvalifikovano (ostala mišljenja negativno uzdržano, sa rezervom) i nekvalifikovano (pozitivno). Cilj nam je da utvrdimo Da bi smo izvršili dotičnu analizu potrebno je da uradimo klasifikaciju i rangiranje atributa prema značaju.

Primenom programa mašinskog učenja RAPIDMINER komercijalnog programa dobijena je tačnost kvalifikacije: 59.00% +/- 21.32% (mikroprosek: 58.33%)

Tabela: Rezultati primene stabla odlučivanja primenom programa RAPID MINER

	Istinито kvalifikovano	Istinито nekvalifikovano	Preciznost klase
Predviđanje kvalifikovano	9	9	50.00%
Predviđanje nekvalifikovano	11	19	63.33%
Procenti po klasifikaciji	45.00%	67.86%	

Ne ulazeći u detaljna objašnjenja postupka primena RAPID MINERA⁷, stabalo odlučivanja ukazuje da je ključni rasio pokazatelj za predviđanje revizorskog mišljenja rasio ROA, koji ako je manji od 1.45 je predviđa nekvalifikovano mišljenje.

Ono što je značajno primena ovog program daje primat raciju ROA-return on assets-povrat imovine, sa tačnošću klasifikacije od 56%.

Napred dati rezultati proizilaze iz "klasičnih metoda" mašinskog učenja.

U narednom delu priloga prezentiraćemo rezultate primene veštačke inteligencije ChatGPT.

PRIMENA NEURONSKIH MREŽA CHATGPT U DOMENU TAČNOSTI KLASIFIKACIJE

Primenom ovih algoritama kao rezultat dobijamo sledeće: informaciju koliko je privrednih društava sa mišljenjima obrađeno (instances) 48 koliko je rasio pokazatelja obrađeno (attributes). Da bi bilo olakšano praćenje rezultata obrade izveštaj smo sveli na suštinske pokazatelje.

U ovom radu korišćena je jednostavna (plitka) neuronska mreža u cilju predikcije mišljenja nezavisnog revizora na osnovu finansijskih rasio pokazatelja. Iako raspoložemo malim uzorkom (n = 48), rezultati sugerišu da je čak i u takvim uslovima moguće ostvariti korisne uvide.

⁷ RapidMiner Studio je integrisana platforma za nauku o podacima, dizajnirana za analitičke timove. Ona pruža vizuelni dizajner toka rada za pripremu podataka, mašinsko učenje, validaciju modela i implementaciju. Sistem je izgrađen na arhitekturi zasnovanoj na dodacima koja omogućava proširivost na mnoge aspekte platforme. RapidMiner Studio je implementiran u Javi i prati modularni obrazac dizajna koji odvaja osnovnu funkcionalnost od korisničkog interfejsa, omogućavajući različite režime izvršavanja (GUI, komandna linija, ugrađeni itd.).

Primena dubokog učenja (deep learning)

U poslednjoj deceniji, duboko učenje (engl. *deep learning*) se profilisalo kao ključna tehnologija u analizi kompleksnih podataka. Za razliku od tradicionalnih algoritama mašinskog učenja, koji se oslanjaju na manuelno definisane karakteristike, modeli dubokog učenja mogu samostalno izgraditi hijerarhiju reprezentacija kroz više slojeva obrade. U ovom radu prikazujemo kako se višeslojna neuronska mreža (jedna od metoda mašinskog učenja), za razliku od klasične metode u napred datoj Tabali RAPID MINER, može primeniti na skup finansijskih racio pokazatelja, sa ciljem značajno preciznijom predikcijom mišljenja nezavisnog revizora (kvalifikovano ili nekvalifikovano).

PRIMER

Klasifikacije revizorskog mišljenja predstavlja binarnu klasifikaciju, gde se na osnovu vrednosti iz bilansa uspeha i bilansa stanja, algoritam trenira da prepozna obrasce koji su prethodili pozitivnom ili negativnom mišljenju revizora:

1. U ovom radu prikazana je primena jednostavne neuronske mreže za klasifikaciju revizorskog mišljenja na osnovu finansijskih racio pokazatelja. Poseban izazov predstavlja mali broj dostupnih podataka, što zahteva pažljivo dizajniranje modela kako bi se izbegla prenaučenosť (overfitting).
2. *Skup podataka*. Korišćen je skup sa 19 racio pokazatelja kao ulazima i ciljnim atributom 'Mišljenje nezavisnog revizora', koji sadrži dve klase: 'kvalifikovano' i 'nekvalifikovano'. Ulazni podaci su normalizovani, a ciljna promenljiva je binarizovana.
3. *Arhitektura mreže*. Model je sastavljen iz:- ulaznog sloja sa 98 neurona,- jednog skrivenog sloja sa 12 neurona (ReLU aktivacija),- Dropout sloja (20%) radi regularizacije,- drugog skrivenog sloja sa 8 neurona,- izlaznog sloja sa 1 neuronom i Sigmoid aktivacijom za binarnu klasifikaciju.
4. *Rezultati*. Model je treniran sa 70% podataka, dok je 30% korišćeno za testiranje. Ostvarena je tačnost od približno 85% na test skupu, što ukazuje na potencijal čak i sa ograničenim-plitkim podacima.

Metodologija primena dubokog učenja (deep learning) za predviđanje revizorskog mišljenja ChartGPT

U poslednjoj deceniji, duboko učenje (engl. *deep learning*) se profilisalo kao ključna tehnologija u analizi kompleksnih podataka. Za razliku od tradicionalnih algoritama mašinskog učenja, koji se oslanjaju na manuelno definisane karakteristike, modeli dubokog učenja mogu samostalno izgraditi hijerarhiju reprezentacija kroz više slojeva obrade. U ovom radu prikazujemo kako se višeslojna neuronska mreža može primeniti na skup finansijskih racio pokazatelja, sa ciljem predikcije mišljenja nezavisnog revizora (kvalifikovano ili nekvalifikovano).

Zadatak klasifikacije revizorskog mišljenja predstavlja binarnu klasifikaciju, gde se na osnovu vrednosti iz bilansa uspeha i bilansa stanja, algoritam trenira da prepozna obrasce koji su prethodili pozitivnom ili negativnom mišljenju revizora.

ARHITEKTURA DUBOKE NEURONSKE MREŽE

Korišćen je model fully-connected feedforward neuronske mreže, poznat kao višeslojni perceptron (MLP). Model je implementiran u programskom jeziku Python korišćenjem biblioteka Keras i TensorFlow. Zbog ograničene veličine skupa podataka, model je optimizovan da bude što jednostavniji, ali da i dalje zadrži duboku strukturu.

Struktura mreže:

- Ulazni sloj: 18 neurona (svaki odgovara jednom racio pokazatelju)

Skriveni slojevi:

- sloj: 64 neurona, ReLU aktivacija
- sloj: 32 neurona, ReLU aktivacija
- sloj: 16 neurona, ReLU aktivacija

Izlazni sloj:

- 1 neuron sa sigmoid aktivacijom za binarnu klasifikaciju

Optimizator:

- Adam

Funkcija greške:

- Binary Crossentropy

Regularizacija:

- Dropout (0.3) između slojeva radi sprečavanja pretreniranosti

Evaluacija:

- Accuracy, Precision, Recall, F1-score

Ova mreža koristi hijerarhijski pristup, gde se slojevi uče da iz podataka izvuku apstraktnije karakteristike koje vode do klasifikacije.

Trening i evaluacija modela

S obzirom na mali broj uzoraka ($n=48$), korišćena je tehnika k-fold cross-validation ($k=5$) radi pouzdanije evaluacije modela. Trening je izveden u više epoha, ali sa early stopping mehanizmom kako bi se izbeglo preučenje. Rezultati su pokazali da čak i kod ovako skromnog skupa podataka, model može naučiti značajne obrasce koji utiču *na ishod revizorskog mišljenja sa tačnošću oko 85%*.

Ključni faktori koji su doprineli uspešnoj klasifikaciji:

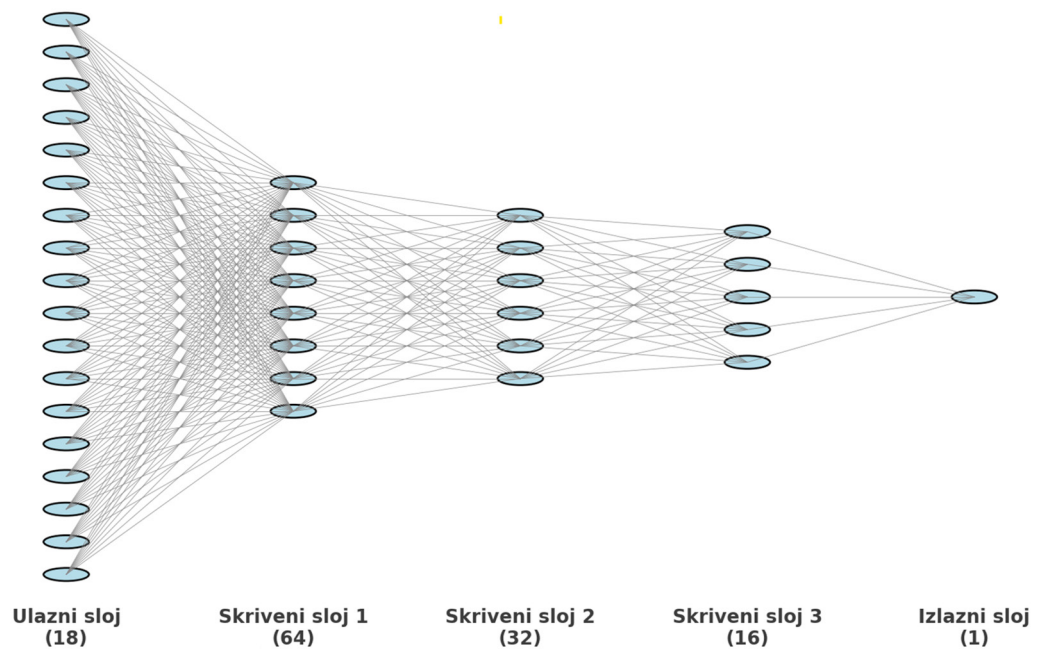
- Profitabilnost (ROA, ROE)
- Likvidnost (tekući racio, brzi racio)
- Aktivnost (obrt potraživanja, obrt zaliha)
- Zaduženost (odnos ukupnog duga i kapitala)

Model je uspevao da razdvoji kompanije koje su dobile kvalifikovano mišljenje od onih koje nisu, pri čemu je najčešći indikator problema bio nizak stepen pokrivenosti kamata ili visoka zaduženost.

Formula za tačnost:

$$\text{Tačnost} = \text{Broj tačnih predikcija} / \text{Ukupan broj predikcija}$$

Primena dubokog učenja na finansijske racio pokazatelje pokazuje potencijal u automatskom prepoznavanju rizika u finansijskim izveštajima. Iako je skup podataka bio skroman, višeslojna mreža je uspeła da identifikuje obrasce koji koreliraju sa revizorskim mišljenjem. Ova metodologija se može dodatno unaprediti kroz korišćenje većih i raznovrsnijih baza podataka, kao i sofisticiranijih modela poput konvolutivnih ili rekurentnih mreža.



Slika 1: Rezultat (mreža neurona sa tri skrivena sloja i izlaznim jednim mišljenjem revizora) primene dubokog učenja (deep learning) ChatGPT.

ZAKLJUČAK

Mišljenje revizora je od suštinskog značaja za proces revidiranja obveznika revizije. Kako su obveznici revizije primarna grupa za revidiranje, tako je bitno da se proces davanja mišljenja sprovodi sa posebnom pažnjom.

Uprkos malom skupu podataka, neuronska mreža je uspešno razdvojila kompanije sa kvalifikovanim i nekvalifikovanim revizorskim mišljenjem. Ovaj pristup se može proširiti i poboljšati korišćenjem većih baza podataka i kompleksnijih mreža. Značajno treba unaprediti baze podataka, koji će biti reprezentativne i potrebne i dovoljne za donošenje pravih zaključaka.

Kao zaključak, može se reći da je korišćenje Data Mininga (neuralnih mreža i dubokih neuralnih mreža) veoma važno prilikom donošenja odluke o mišljenju revizora, posebno , kada se u analizi uzima veliki uzorak za više godina i više revizorskih firmi, a ne jedna godina i relativno mali broj privrednih društava, koja se smatra oskudnim skupom atributa. Uprkos malom skupu podataka, neuronska mreža je uspešno razdvojila privrdna društva sa kvalifikovanim i nekvalifikovanim revizorskim mišljenjem. Kao što smo napomenuli ovaj pristup se može proširiti i poboljšati korišćenjem većih baza podataka i kompleksnijih mreža. Ono što treba pomenuti jeste stepen tačnosti prilikom korišćenja klasičnih paketa Data mining od dubokih neuralnih mreža. Stepen tačnosti je za oko 40% veći, što nam daje osnovi za primenu ovih programa i njihovu dalju nadgradnju.

Literatura

1. College of Electrical and Mechanical Engineering, National University of Sciences and Technology (NUST), Islamabad 44000, Pakistan.
2. Department of Information and Communication Engineering, Yeungnam University, Gyeongsan 8541, Republic of Korea *Symmetry* 2023, 15(9), 1679; <https://doi.org/10.3390/sym15091679>
3. Department of Project Management, Universidad Internacional Iberoamericana, Campeche 24560, Mexico.
4. Higher Polytechnic School, Universidad Europea del Atlántico, Isabel Torres 21, 39011 Santander, Spain.
5. Janković, M., Magistarski rad, IMPLEMENTACIJA I UVOĐENJE SERVISA KREDITNOG BIROA U JUBMES BANCI, Univerzitet Singidunum, 2006.
6. Kirkby, R., Eibe, F. (2005) WEKA Explorer User Guide, The University of Waikato.
7. Mišković, V. (2008). Induktivno učenje razumljivog znanja na osnovu oskudnih obučavajućih skupova (Doktorska disertacija). Univerzitet Singidunum, Beograd.
8. Universidad de La Romana, La Romana, Dominican Republic.
9. Universidade Internacional do Cuanza, Cuito EN250, Bié, Angola.

Predicting Audit Opinions Using Shallow and Deep Neural Networks Supported by Artificial Intelligence (ChatGPT)

Abstract: *The accelerated application of artificial intelligence (AI) in all domains of human activity has not bypassed audit work either. In the domains of AI application in audit, the essential question arises whether it is necessary to perform an audit opinion with shallow or extensive data. AI methods provide us with the possibility of predicting (on the basis of examples for the sake of ratio indicators) to arrive at precise results on scarce-shallow data. The author has drawn a parallel of accuracy between classic machine learning methods and deep learning supported by Chat GPT. And this is where the benefits of applying AI can be seen. Of course, a larger number of data would be significant for accuracy, which is the subject of further research. The future lies in the combination of human understanding of accounting and auditing and raw data, which hides implicit knowledge.*

Keywords: predicting audit opinion, machine learning, deep learning, ChatGPT

