

Aktivno učenje in vzajemnost med učiteljem in učencem

Matjaž Majnik, Danijel Skočaj

Univerza v Ljubljani, Fakulteta za računalništvo in informatiko, Tržaška cesta 25, 1000 Ljubljana, Slovenija
E-pošta: {matjaz.majnik,danijel.skocaj}@fri.uni-lj.si

Povzetek. Osnovni cilj aktivnega učenja je doseči željeno uspešnost danega učnega algoritma s čim manjšim številom učnih primerov. Vzrok te težnje je v dejstvu, da je označevanje učnih primerov običajno drago zaradi količine časa in umskega napora človeškega označevalca. Vendar pa ima aktivno učenje pomanjkljivosti, kot so neupoštevanje stopnje učiteljevega poznavanja problema in pomanjkanje mehanizma za zagotavljanje razumljivosti aktivno izbranih učnih primerov. V tem članku predlagamo nov pristop k aktivnemu učenju, t. i. "vzajemno aktivno učenje", ki umetnemu inteligentnemu učencu pomaga, da svojemu učitelju zastavi kar se da jasna in razumljiva vprašanja. Tovrstno učenje se izkaže za bolj zanesljivo in uspešno v primerjavi z osnovnim aktivnim učenjem.

Ključne besede: aktivno učenje, socialno strojno učenje, učenje konceptualnega znanja, interakcija med človekom in računalnikom, avtonomni razvoj

Active learning and teacher-learner mutuality


In active learning, the basic objective is to reach a desired performance of some learning algorithm with as little training instances as possible. The reason behind is that labeling of the training instances is typically expensive with respect to the amount of time and intellectual effort of a human annotator. However, active learning has shortcomings, for example ignoring the extent of the teacher's familiarity with the problem and absence of a mechanism for ensuring the understandability of the actively selected training instances. In this paper we propose a new approach to active learning, called "mutual active learning". It helps the artificial intelligent learner to pose questions to his human teacher, which are as clear and as understandable as possible. Such learning appears to be more reliable and successful than the basic active learning.

1 UVOD

Učenje je eden temeljnih spoznavnih procesov, tako pri ljudeh kot tudi pri strojih, v katere bi radi vgradili osnovne spoznavne zmožnosti. V umetne sisteme, ki naj bi s človekom sobivali in z njim sodelovali, je namreč tako rekoč nemogoče vnaprej vgraditi celotno znanje, ki ga potrebujejo pri svojem delovanju. Veliko bolj primerno je to znanje postopoma usvajati in ga nadgrajevati v procesu učenja.

Eden najbolj naravnih načinov prenosa znanja, tako s človeka na človeka kot tudi s človeka na inteligentni stroj, je interaktivno učenje v dialogu učenca z učiteljem. Pri klasičnem pristopu učenje vodi učitelj. Pri tem t. i. *pasivnem učenju* učitelj izbere ustrezne učne primere, s katerimi učencu ponazori in ga nauči

določenih konceptov (kot je prikazano na sliki 1(a)). Poznamo tudi primere *aktivnega učenja*, kjer proces učenja vodi učenec. Učenec ima namreč neposreden vpogled v svoje trenutno znanje, zato lahko oceni, kje je le-to najšibkejše, in zahteva takšne učne primere, ki bi učinkoviteje pomagali zapolniti luknje v njegovem znanju (slika 1(b)).



Slika 1: Različne vrste učenja

Temeljni cilj aktivnega učenja je torej pohitritev učnega procesa. V nadaljevanju se bomo omejili na problem učenja konceptualnega znanja oz. učenja kategorizacije primerov v diskretne razrede, ki sovpadajo s človeškim pojmovanjem teh kategorij (npr. kategorizacija predmetov, razpoznavanje barv, razpoznavanje črk in drugih simbolov ipd.). V tem primeru učenec sodeluje pri aktivnem učenju tako, da izbira učne primere, ki so predani učitelju v označevanje (t. j. v dodeljevanje oznak razredov) in nato uporabljeni za učenje. Učenec navadno oceni informativnost še neoznačenih učnih primerov, torej oceni, koliko nove informacije mu bo učni primer prinesel oz. koliko bo lahko na podlagi njega

izboljšal svoje znanje. Obstaja več različnih strategij za ocenjevanje informativnosti (t. i. *strategij poizvedovanja*, angl. *query strategies*) [8], [5]. V našem predhodnem delu [9], [4] smo proučevali in vrednotili razne pristope, ki delujejo na podlagi teh strategij poizvedovanja in se uporabljajo za končni izbor najprimernejšega učnega primera, ki naj bi se ga označilo v vsakem koraku aktivnega učenja.

Pri svojem delu predpostavljamo socialno interaktiven scenarij, kjer človeški učitelj interaktivno komunicira z inteligentnim sistemom. V tem scenariju je motivacija za aktivno učenje v zmanjševanju časa in napora, ki ga učitelj vloži v učenje, in sicer primarno z zmanjšanjem števila učnih primerov, ki morajo biti označeni. Treba pa se je zavedati, da se težavnost klasifikacije (t. j. prirejanja primernih oznak razredov) med primeri razlikuje. Na splošno velja, da so dvoumni primeri v bližini mej med razredi (ki pa so pogosto najbolj informativni) lahko za učitelja težavnejši, saj lahko njihovo označevanje zahteva več napora in časa. Pri aktivnem učenju, kjer učenec sam generira učne primere, so lahko posamezni primeri tudi popolnoma nerazumljivi ali celo nesmiselni v kontekstu danega učnega problema.

Recimo, da pri učenju dovolimo predpostavko iz realnega sveta, in sicer, da *človeški učitelji niso vsevedni* in se lahko motijo. Tedaj spoznamo, da izbira primerov ne bi smela temeljiti le na *informativnosti*, temveč tudi na *razumljivosti*, torej na tem, kako dobro učitelj razume ponujene mu učne primere. V ta namen predlagamo nov pristop k aktivnemu učenju, poimenovali smo ga *vzajemno aktivno učenje*, ki naj bi težil k temu, da bi bili informativni primeri, izbrani s pomočjo aktivnega učenja, obenem tudi razumljivi človeškemu učitelju. Koncept tovrstnega učenja na področju umetne inteligence, po našem najboljšem vedenju, še ni bil raziskan. Izraz "vzajemno" nakazuje, da ima pri predlaganem načinu učenja tudi učitelj vpliv na izbiro učnih primerov, ki mu jih v označevanje pošilja učenec, kot je ponazorjeno na sliki 1(c). V tem članku je predstavljena idejna zasnova novega pristopa s potrditvijo njene uporabnosti. Izvedeno eksperimentalno vrednotenje je na primeru učenja koncepta barv potrdilo, da je takšno učenje zanesljivejše in uspešnejše kot osnovno aktivno učenje.

Zgradba članka je naslednja. V poglavju 2 najprej povzamemo sorodno delo. V poglavju 3 nato predstavimo predlagani pristop za vzajemno aktivno učenje. Sledi poglavje 4, v katerem opišemo eksperimentalno vrednotenje, članek pa s končnimi ugotovitvami sklenemo v poglavju 5.

2 SORODNO DELO

Eno izmed področij, ki bi z vzajemnim aktivnim učenjem lahko veliko pridobila, je robotika osebnih pomočnikov (angl. *socially assistive robotics*). Glavni cilj robotike osebnih pomočnikov je gradnja robotov, ki so skozi socialno interakcijo sposobni pomagati

človeškim uporabnikom in tako prispevati h kakovosti njihovega življenja [10]. Tovrstni roboti naj bi bili zmožni naravne komunikacije in socialne interakcije, še zlasti pa bi prišli prav populaciji starostnikov in ljudem s kognitivnimi, razvojnimi in socialnimi hibami. Pri takšnih namenih uporabe je izjemno pomembna razumljivost robotovih vprašanj, zagotavljanju katere pa je, med drugim, namenjeno vzajemno aktivno učenje.

V našem scenariju interaktivnega učenja komunikacija poteka v obliki izmenjevanja vprašanj in odgovorov na ta vprašanja. Da bi učitelj lahko ustrezno odgovoril na vprašanje, mora vprašanje razumeti. Lastnosti dobrega vprašanja so s stališča strojnega in tudi človeškega učenja proučene v [1]. Avtorji pri tem identificirajo tri različne vrste poizvedb (oz. vprašanj) in jih ovrednotijo v človeško-robotskem učnem eksperimentu. Rezultati nakazujejo, da ljudje poizvedbe o značilkah (t. j., ali je značilka pomembna za koncept, ki se ga učimo, angl. *feature queries*) dojemajo kot najbolj inteligentne, medtem ko je na splošno ljudem najlažje odgovarjati na poizvedbe o oznakah razredov (t. j., kateremu razredu pripada posamezen neoznačeni učni primer, angl. *label queries*). Poizvedbe o oznakah razredov so tudi tip poizvedb, ki jih uporabljamo v našem članku, po drugi strani pa [1] ne vsebuje izrecne obravnave vzajemnosti, t. j. učiteljevega vpliva na izbiro učenčevih vprašanj.

Ena glavnih predpostavk v našem članku, predpostavka o šumnih človeških učiteljih, je bila v [8] naslovljena kot eden izmed izzivov pri praktični uporabi aktivnega učenja. Problem je bil nadalje proučen v [2], kjer avtorji obravnavajo obnašanje človeških strokovnjakov pri dogodkih v realnem svetu. Avtorji v svoji študiji predpostavljajo, da naj bi tedaj, ko je strokovnjak zelo prepričan o označevanih učnih primerih, tudi verjetnost pravilnosti teh oznak bila visoka. Predstavljena je analiza o tem, v katerih primerih in kako človeški strokovnjaki posredujejo nepravilne odgovore. Na podlagi rezultatov analize je predlagana nova metoda za iskanje ravnovesja med izbiro primerov, ki so zelo informativni (vendar pa bo strokovnjak nekatere izmed njih verjetno napačno označil), in primerov z visoko verjetnostjo dodelitve pravilne oznake (ki pa imajo majhno informativno vrednost). To iskanje ravnovesja, čeprav naslovljeno z drugega zornega kota, predstavlja tudi osnovno idejo našega članka. Omenjeni problem je poznan tudi pod imenom *kompromis med raziskovanjem in uporabo* (angl. *exploration/exploitation dilemma*) in je nadalje obravnavan v [6].

Običajno pri učenju umetnih inteligentnih sistemov sodelujejo učitelji, ki se na tematiko učenja spoznajo. Rečemo lahko, da je učitelj v tem primeru *strokovnjak* za dano tematiko. Predlagano vzajemno aktivno učenje naj bi bilo pri učenju s strokovnjaki uspešnejše od osnovnega aktivnega učenja. Prednosti vzajemnega aktivnega učenja pa naj bi se v še večji meri kot pri strokovnjakih, ki (bolj ali manj dobro) razumejo učenčeva vprašanja in (praviloma) sorazmerno suvereno (pravilno, natančno)

odgovarjajo na vprašanja, pokazale pri učiteljih – *nestrokovnjakih*. Enega izmed scenarijev, kjer robota poučujejo nestrokovnjaki, proučujejo avtorji v [7]. Obravnavani so štirje različni tipi dodatne informacije o robotovem stanju, ki naj bi bila v pomoč učitelju – nestrokovnjaku. Velika razlika v primerjavi z našim pristopom pa je v tem, da mi predpostavljamo, da ima učitelj *dejavno* vlogo pri sporočanju, katere informacije so zanj osebno bolj razumljive (učenec se tako lahko prilagodi znanju posameznega učitelja).

3 VZAJEMNO AKTIVNO UČENJE

Vodilo pri razvoju predlaganega pristopa so ugotovljene pomanjkljivosti osnovnega aktivnega učenja. V razdelku 3.1 primerjamo lastnosti osnovnega aktivnega učenja in vzajemnega aktivnega učenja s stališča splošne motivacije, želja človeškega učitelja in nalog umetnega inteligentnega učenca. V 3.2 nato orišemo predlagani pristop k vključevanju "vzajemnosti" v aktivno učenje. Postavljene hipoteze so navedene v razdelku 3.3.

3.1 Osnovno in vzajemno aktivno učenje

- 1) Aktivno učenje (AU):
 - a) splošna motivacija: Prenos znanja z učitelja na učenca s pomočjo najmanjšega mogočega števila učnih primerov.
 - b) človeški učitelj: "Učenec, prosim, uči se kar se da hitro, moj čas in napor sta dragocena."
 - c) umetni inteligentni učenec: "Učitelj, prosim, podaj mi primere, ki mi bodo omogočili, da se čim hitreje naučim."
- 2) Vzajemno aktivno učenje (VAU):
 - a) splošna motivacija: Kot v AU + s čim manj učiteljevega umskega napora.
 - b) človeški učitelj: Kot v AU + "Učenec, prosim, zastavljam vprašanja, ki so čim manj neprijetna/težavna (da bom tako lahko na vsako vprašanje odgovoril čim bolj zanesljivo in čim hitreje)."
 - c) umetni inteligentni učenec: Kot v AU.

3.2 Upoštevanje učiteljevega odziva

V tem delu smo učiteljev odziv upoštevali na naslednji način. Namesto enega samega učenca v vsaki posamezni interakciji z učiteljem le-temu v označevanje ponudi množico neoznačenih učnih primerov. Učenec vedno ponudi množico primerov, ki so zanj posamično čim bolj koristni. To množico učenec sestavi tako, da oceni informativnost vseh razpoložljivih primerov in izbere tiste z najvišjo vrednostjo informativnosti. Učitelj nato izmed ponujenih izbere in označi tisti primer, ki je zanj najbolj razumljiv. Ta (sedaj že označeni) primer se zatem uporabi za učenje v dani interakciji.

Pri sami implementaciji smo uporabili usmerjeno vzorčenje negotovosti (angl. *directed uncertainty sampling*), ki temelji na izračunu aposteriorne verjetnosti

preko vseh mogočih razredov. To vzorčenje je izvedeno v metodi tipa Monte Carlo, ki je bila opisana v [4]. Z vzorčenjem prostora značilke se ustvarjajo učni primeri, ki so nato ponujeni učitelju v označevanje. Proces ustvarjanja učnih primerov je popolnoma introspektiven (učenec torej analizira svoje modele in se ne sklicuje na učne primere iz realnega sveta). Več informacij o introspekciji lahko prav tako najdete v [4].

3.3 Naše hipoteze

Ker pri vzajemnem aktivnem učenju učenec v vsaki interakciji učitelju ponudi le primere, ki so zanj približno enako koristni, v splošnem ne bi smela obstajati nevarnost, da bi predlagana metoda imela kakršenkoli negativen vpliv na končno stopnjo uspešnosti (merjeno npr. v obliki klasifikacijske točnosti). Naše hipoteze so tako naslednje:

- 1) Stopnja uspešnosti naj bi se povečala, in sicer zato, ker so učni primeri, ki so učitelju predstavljeni, le-temu verjetno bolj razumljivi. Učitelj jih torej lahko označi z večjo zanesljivostjo.
- 2) Skupni čas učenja naj bi se skrajšal, saj naj bi za učitelja označevanje posameznih učnih primerov, ki jih le-ta bolje razume (je z njimi bolj seznanjen ali pa so bolj nedvoumni), bilo časovno manj zahtevno. Ali se čas učenja tudi dejansko skrajša pa naj bi bilo odvisno od domene, natančneje, kako pomembno je za človeškega označevalca v dani domeni, da se izogne morebitnim napačnim klasifikacijam. Predpostavljamo, da naj bi se s povečevanjem pomembnosti časa učenja skrajševal v primerjavi s časom učenja pri osnovnem aktivnem učenju.
- 3) Umska obremenitev človeškega učitelja naj bi se zmanjšala, in sicer zaradi bolj razumljivih učnih primerov.

4 EKSPERIMENTALNO VREDNOTENJE

V razdelku 4.1 najprej opišemo preizkusno domeno, predstavimo primerjane načine učenja ter navedemo in opišemo množice učnih primerov, ki so jih učitelji označevali. V razdelku 4.2 sledi časovni potek poizkusa. Prikazan je uporabniški vmesnik, predstavljena pa so tudi navodila, ki so jih pred začetkom poizkusa dobili učitelji. Mere, ki smo jih uporabili za subjektivno in objektivno vrednotenje rezultatov, so podane v razdelku 4.3, rezultati poizkusa pa so na voljo v razdelku 4.4.

4.1 Zasnova poizkusa

Hipoteze so bile preizkušene na problemu razpoznavanja barvnih vzorcev, pridobljenih iz prostora HSL. Prostor HSL je pri tem trirazsežni prostor, kjer značilke H (barvni odtenek, angl. *hue*), S (nasičenost, angl. *saturation*) in L (svetlost, angl. *lightness*) predstavljajo po eno izmed razsežnosti. Naloga je bila dodeliti predstavljenim vzorcem oznako ene izmed naslednjih osmih

barv (razredov): rdeče, rumene, modre, oranžne, zelene, rožnate, črne in bele. Ta domena ima naslednji dve lastnosti, zaradi katerih ustreza našemu namenu:

- Pojmovanje barv je že po naravi, vsaj do neke mere, subjektivno. Strogo določene meje med različnimi barvami ne obstajajo.
- Oznake nekaterih tipičnih barv manjkajo (npr. rjave, vijoličaste in sive). Učitelji se morajo odločiti, katera od oznak, ki so na voljo, najbolj opisuje dani barvni vzorec, lahko pa tudi izberejo možnost “Nobena od razpoložljivih”.

Pri vrednotenju smo uporabili štiri načine učenja, med njimi dva pomožna (*naključni* in *večnaključni*).

- 1) *vzajemni* – Vzajemno aktivno učenje. Pri vsaki interakciji je več barvnih vzorcev pridobljenih s postopkom, ki je opisan v razdelku 3.2. Ti barvni vzorci so nato ponujeni v označevanje.
- 2) *osnovni* – Osnovno aktivno učenje. Pri vsaki interakciji je pridobljen samo en barvni vzorec (s pomočjo enakega postopka kot pri *vzajemnem* načinu). Ta barvni vzorec je nato ponujen v označevanje.
- 3) *naključni* – Naključno učenje. Pri vsaki interakciji je barvni vzorec ustvarjen naključno. Ta barvni vzorec je nato ponujen v označevanje.
- 4) *večnaključni* – Večnaključno učenje. Pri vsaki interakciji je več barvnih vzorcev ustvarjenih naključno. Vsi ti barvni vzorci so nato ponujeni v označevanje.

Pri poizkusu je sodelovalo osem učiteljev, pet jih je pripadalo starostni skupini 20–30 let, preostali trije pa starostni skupini 30–40 let. Tri osebe so bile ženskega spola, pet moškega. Vsak izmed učiteljev je skupaj dodelil oznake razredov 840 barvnim vzorcem, ki so pripadali naslednjim množicam:

- začetna učna množica ($L1$) z 80 barvnimi vzorci (uravnovežena porazdelitev po razredih s po 10 barvnimi vzorci na razred),
- interaktivne učne množice ($L2$) s po 50 barvnimi vzorci za vsako izmed 3 ponovitev pri vsakem izmed 4 načinov učenja, skupaj torej s $3 \times 4 \times 50$ barvnimi vzorci (v splošnem neuravnovežena porazdelitev po razredih),
- in preizkusna množica (T) s 160 barvnimi vzorci (uravnovežena porazdelitev po razredih s po 20 barvnimi vzorci na razred).

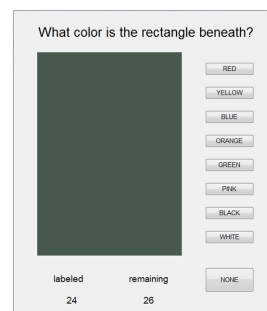
Za zanesljivejšo primerjavo rezultatov so bili barvni vzorci začetne učne množice in preizkusne množice za vse učitelje enaki. Vsi učitelji so torej prejeli enake barvne vzorce, oznake razredov pa je tem barvnim vzorcem individualno priredil vsak učitelj posebej. Po drugi strani pa je bila izdelana unikatna interaktivna učna množica za vsako kombinacijo (*učitelj, ponovitev, način učenja*). Skupno število takšnih interaktivnih učnih množic je torej $8 \times 3 \times 4 = 96$.

4.2 Izvedba poizkusa

Poizkus je bil izveden na zgoraj opisanem interaktivnem učnem sistemu, ki je tekel na osebem računalniku. Kot temeljni učni algoritem smo uporabili odKDE [3]. Učni sistem je omogočal interaktivno komunikacijo in človeški učitelji so odgovarjali na vprašanja, ki jih je sistem zastavljal.

Učiteljem so bila podana naslednja navodila:

- Načina *naključni* in *osnovni* (tip A): Barvnemu vzorcju dodelite oznako ene izmed 8 razpoložljivih barv. Če se ne morete odločiti za nobeno od teh barv, izberite možnost “Nobena od teh”.
- Načina *večnaključni* in *vzajemni* (tip B): Izberite enega izmed 15 ponujenih vzorcev, za katerega se lahko odločite, katere barve je. Izbranemu barvnemu vzorcju dodelite oznako ene izmed 8 razpoložljivih barv. Če ne morete nobene izmed oznak dodeliti nobenemu izmed 15 vzorcev, izberite možnost “Nobena od teh”. Poizkusite naučiti sistem razlikovati med koncepti vseh 8 barv (torej, če je mogoče, težite k izbiri vzorcev različnih barv).




Slika 2: Uporabniški vmesnik pri tipu A

Najprej je vsak učitelj označil 240 barvnih vzorcev; 80 jih je bilo namenjenih začetni učni množici ($L1$), 160 pa uporabljenih za preizkusno množico (T). Nato se je vsak učitelj soočil z vsakim od štirih načinov učenja (predstavljenih v razdelku 4.1) v treh zaporednih ponovitvah. Načini učenja določajo, kako je (so) v vsaki interakciji ustvarjen (-i) vektor (-ji) značilnik, ki je (so) nato učitelju prikazan (-i) v obliki barvnega (-ih) vzorca (-ev). Učitelj je torej označil 12 unikatnih interaktivnih učnih množic, kjer je vsaka množica ustrezala enemu izmed 12 parov (*ponovitev, način učenja*). Učitelji niso bili seznanjeni z nikakršnimi dodatnimi informacijami o predpostavljene kakovosti uporabljenih načinov učenja. Nazadnje je vsak učitelj odgovoril na štiri vprašanja o svoji interakciji s sistemom.

Uporabniški vmesnik, ki je bil učiteljem na voljo pri načinih tipa A oz. B, je prikazan na slikah 2 in 3.

4.3 Objektivne in subjektivne mere vrednotenja

Objektivno izmerjeni količini pri eksperimentalnem vrednotenju (pri stalnem številu učnih primerov – barvnih vzorcev) sta bili čas učenja in uspešnost učenja.



Slika 3: Uporabniški vmesnik pri tipu B

Čas učenja se je meril od trenutka, ko je bilo učitelju zastavljeno prvo vprašanje, do trenutka, ko je učenec prejel zadnji odgovor. Stopnja uspešnosti pa je bila ugotovljena z izračunom klasifikacijske točnosti.

Subjektivno vrednotenje umske obremenitve človeških učiteljev je bilo izvedeno na podlagi naslednjega vprašalnika, ki so ga učitelji dobili, ko je bil učni proces končan.

V osnovi ste se srečali z dvema tipoma načinov za označevanje barvnih vzorcev:

- tip A: brez možnosti izbire (vedno na voljo le en vzorec),
- tip B: z možnostjo izbire (vedno na voljo 15 vzorcev).

Prosimo, odgovorite z A ali B na naslednja štiri vprašanja. Svoje odločitve na kratko obrazložite.


- 1) Kateri od obeh tipov vam je omogočil hitreje odločanje o tem, katere barve je (izbrani) vzorec? Zakaj?
- 2) Pri katerem izmed obeh tipov je bilo po vašem mnenju učenje uspešnejše? Zakaj?
- 3) Kateri izmed obeh tipov se vam je zdel umsko manj zahteven? Zakaj?
- 4) Pri katerem izmed obeh tipov ste se počutili (bolj) negotovo? Zakaj?

4.4 Rezultati in razprava

Na sliki 4 vidimo krivulje srednje klasifikacijske točnosti, ki so bile izračunane iz posameznih rezultatov vseh 8 učiteljev in vseh 3 ponovitev, ki jih je opravil vsak izmed učiteljev. Najprej lahko opazimo, da je bil proces interaktivnega učenja v vseh primerih uspešen. Klasifikacijska točnost narašča s številom učnih primerov; ta rast je najbolj izrazita na začetku učnega procesa, ko se sistem uči novih konceptov, vendar v glavnem ostaja pozitivna tudi v kasnejših obdobjih učenja, ko se naučeni modeli izpopolnjujejo na osnovi novih učnih primerov.

V prvih fazah učnega procesa *osnovno* aktivno učenje ni najbolj uspešno, ker se modeli, na podlagi katerih učenec izbira učne primere, šele gradijo. Ko pa so modeli dovolj zanesljivi, se proces učenja zelo pospeši, tako

da je ta način po pričakovanjih boljši kot *naključni* način, pri katerem se učni primeri izbirajo naključno. Zaradi vloženega človeškega napora je tudi *večnaključni* način boljši od naključnega; v tem primeru namreč učenje z izbiranjem med ponujenimi naključno izbranimi vzorci vsaj deloma usmerja učitelj. Za najboljšega med vsemi pa se je izkazal *vzajemni* aktivni način. Ta način na koncu učenja doseže največjo klasifikacijsko točnost, poleg tega pa tudi med samim učenjem visoko klasifikacijsko točnost doseže prej kot drug načini učenja. Ti rezultati torej potrjujejo našo prvo hipotezo, ki je predvidevala, da se bo zaradi večje razumljivosti učnih primerov klasifikacijska točnost povečala.



Slika 4: Srednja klasifikacijska točnost

Tabela 1 prikazuje srednji čas označevanja enega barvnega vzorca, povprečen preko vseh učiteljev in vseh ponovitev. Opazimo lahko, da je v nasprotju z našo drugo hipotezo srednji kosmati čas označevanja posameznega barvnega vzorca za približno 42 % višji pri *vzajemnem* (4.4 s) kot pri *osnovnem* (3.1 s) aktivnem načinu. Kosmati čas pri *osnovnem* načinu sestoji iz časa odločanja o oznaki in časa klika. Po drugi strani pa pri *vzajemnem* načinu kosmati čas vključuje čas odločanja o izbiri barvnega vzorca, čas klika, čas odločanja o oznaki in še čas drugega klika. Verjamemo pa, da bi v domenah, kjer so posledice dodelitve napačne oznake učnemu primeru lahko resne, npr. v varnostno-občutljivih in medicinskih aplikacijah, kosmati čas praviloma moral biti večji pri *osnovnem* kot pri *vzajemnem* načinu. Po našem mnenju bi se težavnost označevanja tipičnega aktivno pridobljenega primera odrazila v času, ki bi presegal vsoto časa odločanja o izbiri primera in časa drugega klika. Kakorkoli že, na osnovi rezultatov poizkusa, druge hipoteze, ki je predvidevala skrajšanje skupnega časa učenja, ne moremo potrditi.

Po drugi strani se je treba zavedati, da ima povečanje

klasifikacijske točnosti za posledico skrajšanje časa učenja, ki je potreben za doseg neke določene klasifikacijske točnosti. Na primer, za doseg 92-odstotne klasifikacijske točnosti mora učitelj označiti 119 barvnih vzorcev v *osnovnem* načinu aktivnega učenja in le 97 barvnih vzorcev v *vzajemni* različici aktivnega učenja.

Tabela 1: Srednji čas označevanja enega barvnega vzorca

naključni	več-naključni	osnovni	vzajemni
3.2 s	4.7 s	3.1 s	4.4 s

Rezultati subjektivnega vrednotenja so predstavljeni v tabeli 2. Opazimo lahko, da je velika večina učiteljev pri vprašanjih 1, 2 in 4 bolj naklonjena tipu B. Tip B ima pred tipom A prednost tudi pri vprašanju 3, se pa pri tem vprašanju mnenja učiteljev najbolj razlikujejo: medtem ko se pri tipu A ni bilo treba odločiti o tem, kateri barvni vzorec izbrati za označevanje, pa je bilo pri tipu B preprostejše samo označevanje izbranega barvnega vzorca. Iz rezultatov torej lahko sklepamo, da se je umska obremenitev človeškega učitelja pri vzajemnem aktivnem učenju zmanjšala, kar potrjuje našo tretjo hipotezo.

Tabela 2: Subjektivno vrednotenje

vprašanje	odgovor A	odgovor B	drugo
1	0	6	2
2	1	5	2
3	3	4	1
4	7	1	0

5 SKLEP

V tem članku smo predlagali nov koncept za izboljšanje uspešnosti in učinkovitosti aktivnega učenja, ki smo ga poimenovali *vzajemno aktivno učenje*. Glavna lastnost predlaganega pristopa je, da pri izbiri učnih primerov v procesu aktivnega učenja sodelujeta tako učenec kot učitelj. Pri tej izbiri se tako poleg ocenjevanja informativnosti primerov omogoči tudi upoštevanje njihove razumljivosti. Predstavili smo lastnosti predlaganega pristopa in tudi njegove pričakovane prednosti. Empirično vrednotenje pristopa na primeru učenja koncepta barv je potrdilo dve naši hipotezi.

Ker je osnovna ideja vzajemnega aktivnega učenja neodvisna od domene, je predlagani pristop primeren tudi za uporabo na drugih področjih. Pri bodočem delu bomo tako med drugim raziskali obnašanje in uspešnost vzajemnega aktivnega učenja na drugih domenah (npr. na problemu razpoznavanja ročno pisanih števk).

Vzajemno aktivno učenje se približuje predpostavkam realnega sveta in naj bi pomagalo zmanjšati količino časa in napora, ki ga mora učitelj vložiti v proces učenja umetnega inteligentnega sistema. Pri praktični uporabi

takšnih sistemov bi bila predlagana izboljšava zelo dobrodošla. Zavoljo hitrejšega in človeku bolj prijaznega učenja lahko torej pričakujemo, da bodo tovrstni pristopi igrali pomembno vlogo pri načrtovanju interaktivnih socialnih aplikacij.

ZAHVALA

Zahvaljujemo se vsem, ki so v vlogi učitelja sodelovali pri preizkušanju predlagane vzajemne metode in tako omogočili njeno objektivno in subjektivno vrednotenje.

LITERATURA

- [1] M. Cakmak and A. L. Thomaz. Designing robot learners that ask good questions. In *Proceedings of the 7th ACM/IEEE International conference on human-robot interaction(HRI)*, pages 17–24, 2012.
- [2] J. Du and C. X. Ling. Active learning with human-like noisy oracle. In *Proceedings of the 10th IEEE International conference on data mining (ICDM)*, pages 797–802, 2010.
- [3] M. Kristan and A. Leonardis. Online discriminative kernel density estimator with Gaussian kernels. *IEEE Transactions on Systems, Man, and Cybernetics Part B: Cybernetics*, In press (2013).
- [4] M. Majnik, M. Kristan, and D. Skočaj. Knowledge gap detection for interactive learning of categorical knowledge. In *Proceedings of the 18th Computer Vision Winter Workshop*, pages 94–101, 2013.
- [5] Fredrik Olsson. A literature survey of active machine learning in the context of natural language processing. Technical report SICS T2009:06, Swedish Institute of Computer Science, 2009.
- [6] T. Osugi, D. Kun, and S. Scott. Balancing exploration and exploitation: A new algorithm for active machine learning. In *Proceedings of the 5th IEEE International conference on data mining (ICDM)*, pages 330–337, 2005.
- [7] S. Rosenthal, M. Veloso, and A. K. Dey. Acquiring accurate human responses to robots' questions. *International journal of social robotics*, 4(2):117–129, 2012.
- [8] Burr Settles. Active learning literature survey. Technical report 1648, University of Wisconsin-Madison, 2010.
- [9] D. Skočaj, M. Majnik, M. Kristan, and A. Leonardis. Comparing different learning approaches in categorical knowledge acquisition. In *Proceedings of the 17th Computer Vision Winter Workshop*, pages 65–72, 2012.
- [10] Adriana Tapus, Maja J. Matarić, and Brian Scassellati. The grand challenges in socially assistive robotics. *IEEE Robotics and Automation Magazine*, 14(1):35–42, 2007.

Matjaž Majnik je diplomiral leta 2011 na Fakulteti za računalništvo in informatiko (FRI) Univerze v Ljubljani, izobraževanje pa tam nadaljuje tudi v okviru doktorskega študija. Na FRI se je konec leta 2011 zaposlil kot raziskovalec in asistent, njegovi raziskovalni interesi pa so aktivno strojno učenje ter interaktivni prenos znanja s človeka na umetne inteligentne sisteme.

Danijel Skočaj je docent na Fakulteti za računalništvo in informatiko Univerze v Ljubljani, kjer je vodja Laboratorija za umetne vizualne spoznavne sisteme. Njegova raziskovalna dejavnost zajema področja umetnih spoznavnih sistemov in inteligentne robotike, računalniškega in umetnega spoznavnega vida ter interaktivnega socialnega in strojnega učenja.