

PREPOZNAVNA POLOŽAJA TELESA S STROJNIM UČENJEM

Mitja Luštrek, Matjaž Gams
Odsek za inteligentne sisteme
Institut Jožef Stefan

Jamova cesta 39, 1000 Ljubljana, Slovenija
Telefon: +386 1 4773380; telefaks: +386 1 4773131
E-pošta: mitja.lustrek@ijs.si

POVZETEK

Iz koordinat 12 značk, pritrjenih na sklepe, smo s strojnim učenjem prepoznavali položaj telesa. V ta namen smo uporabili tri naborne atributov: (1) koordinate značk in iz njih izpeljane attribute v referenčnem koordinatnem sistemu, (2) koordinate in izpeljane attribute v telesnem koordinatnem sistemu in (3) kote med deli telesa. Za prepoznavanje položaja telesa smo uporabili osem algoritmov za strojno učenje. Ugotovili smo, da so najboljši atributi v referenčnem koordinatnem sistemu, med algoritmi za strojno učenje pa se najboljše obnese metoda podpornih vektorjev.

1 UVOD

Metode za prepoznavanje položaja telesa, ki jih opisujemo v prispevku, so namenjene uporabi v projektu Confidence [1]. Cilj projekta je starejše osebe opremiti z radijskimi značkami, s pomočjo katerih bo moč zaznavati položaj telesa in na podlagi tega ugotavljati zdravstvene težave, posebej padce.

Ker značke in senzorje, ki bodo uporabljene v projektu, partnerji še razvijajo, smo namesto njih uporabili infrardeči sistem Smart [2]. Osebam smo na telo pričvrstili 12 značk, ki odsevajo v infrardeči svetlobi. S šestimi infrardečimi kamerami smo ugotavljali koordinate teh značk v prostoru in jih klasificirali v šest dejavnosti ali stanj. Ker je infrardeča tehnologija bistveno natančnejša od radijske (~ 1 mm proti ~ 15 cm), smo vhodne podatke zašumili.

Položaj telesa smo prepoznavali s strojnim učenjem. Uporabili smo različne naborne atributov: koordinate značk in iz njih izpeljane attribute v koordinatnem sistemu, vezanem na prostor, koordinate in izpeljane attribute v različnih koordinatnih sistemih, vezanih na telo, in kote med deli telesa. Preizkusili smo osem algoritmov za strojno učenje iz programskega paketa Weka [5].

2 VHODNI PODATKI

Uporabili smo po 45 posnetkov gibanja treh oseb. Posnetke smo razbili na več dejavnosti (ali stanj), ki smo jih nato skušali prepoznati.

- 3×15 posnetkov padanja na različne načine (glavni cilj projekta), sestavljenih iz hoje, padanja in ležanja.

- 3×10 posnetkov uleganja (podobno padanju), sestavljenih iz hoje, uleganja in ležanja.
- 3×10 posnetkov usedanja (tudi nekoliko podobno padanju), sestavljenih iz hoje, usedanja in ležanja.
- 3×10 posnetkov hoje.

Posnetki vsebujejo koordinate 12 značk, pritrjenih na rami, komolca, zapestji, kolka, kolena in gležnja. Koordinate so bile zajete s frekvenco 60 Hz, kar smo zmanjšali na 10 Hz, ker je tolikšna frekvenca pričakovana pri radijski opremi, ki se bo uporabila v projektu. Posnetke, ki so se končali z ležanje ali sedenjem, smo podaljšali z 2 s mirovanja: 20-krat smo kopirali zadnji posnetek in vsakič dodali Gaussov šum s $\sigma = 0,2$ cm, da mirovanje ni bilo popolno. Da bi bili podatki bolj podobni zajetim z radijsko opremo, smo jih zašumili z Gaussovimi šumi s $\sigma = 4,36$ cm v smereh x in y ter $\sigma = 5,44$ cm v smeri z . Tolikšen je namreč standardni odklon šuma sistema za določanje položaja Ubisense [4], ki je podoben onemu, ki se bo uporabil v projektu. Zašumljene podatke smo zgladili z enosmernim Kalmanovim filtrom (za glajenje uporablja zgolj pretekle koordinate) [3].

3 ATRIBUTI ZA STROJNO UČENJE

Želeli smo dognati, kolikšno uspešnost je mogoče doseči z enostavnimi in splošnimi atributi. Splošnost je pomembna, ker ni težko izbrati atributov, ki bi bili prilagojeni našim posnetkom in zato na njih zelo uspešni. A ker je s posnetki nemogoče zajeti ves razpon človeškega obnašanja, se taki atributi na splošnem obnašanju verjetno ne bi obnesli.

Atributni vektor smo sestavili iz $N = 10$ zaporednih posnetkov položaja telesa (kar pomeni eno sekundo), razred pa je bila ena od šestih dejavnosti (hoja, padanje, ležanje, uleganje, usedanje, sedenje). Preizkusili smo tudi $N = 20$, a rezultati niso bili bistveno različni, zato smo zaradi kratkosti nekaterih posnetkov uporabili krajši interval. Pri atributnih vektorjih, ki so vsebovali več dejavnosti, smo za razred izbrali najdaljšo. Za vsak posnetek smo izračunali več naborov atributov.

3.1 Atributi v referenčnem koordinatnem sistemu

Referenčni koordinatni sistem je koordinatni sistem prostora, v katerem se opazovana oseba giblje, in je nepremičen. Koordinat x in y nismo upoštevali, ker ni pomembno, kje v prostoru oseba je.


Gornji indeks t pomeni čas znotraj intervala: $t = 1 \dots N$. Spodnji indeks i pomeni značko: $i = 1 \dots 12$. Spodnji indeks R pomeni referenčni koordinatni sistem.

- z_{iR}^t ... koordinata z značke i v času t
- v_{iR}^t ... absolutna hitrost značke
- v_{ziR}^t ... hitrost značke v smeri z
- d_{ijR}^t ... absolutna razdalja med značkama i in j ; $j = i + 1 \dots 12$
- d_{zijR}^t ... razdalja med značkama i in j v smeri z

3.2 Atributi v telesnem koordinatnem sistemu

Telesni koordinatni je pripet na opazovano osebo in omogoča opazovanje koordinat x in y . V njem ti dve koordinati namreč nista odvisni od položaja osebe v prostoru, temveč le opisujeta medsebojna razmerja položajev značk.

Telesni koordinatni sistem je prikazan na sliki 1. Njegovo izhodišče O je na sredini med levo in desno kolčno značko (H_R in H_L). Premica skozi H_R in H_L določa os y , ki je usmerjena proti levemu kolku. Os z je pravokotna na y , se dotika premice, ki povezuje ramenski znački (S_R in S_L) v točki S_z , in je usmerjena navzgor. Os x je pravokotna na y in z ter je usmerjena naprej.



Slika 1. Telesni koordinatni sistem.

Za pretvorbo koordinat iz referenčnega v telesni koordinatni sistem moramo izraziti izhodišče O ter bazne vektorje i , j in k telesnega koordinatnega sistema v referenčnem. Krepka pisava označuje vektorje in x pomeni vektor iz izhodišče do točke X . Enačba (1) da izhodišče koordinatnega sistema.

$$\mathbf{o} = \frac{\mathbf{h}_L + \mathbf{h}_R}{2} \quad (1)$$

Bazni vektor j se izračuna z enačbo (2).

$$\mathbf{j} = \frac{\mathbf{h}_L - \mathbf{o}}{|\mathbf{h}_L - \mathbf{o}|} \quad (2)$$

Da dobimo k , najprej izračunamo s_z z enačbo (3).

$$\begin{aligned} \mathbf{s}_z &= \mathbf{s}_R + a(\mathbf{s}_L - \mathbf{s}_R) \\ (\mathbf{s}_z - \mathbf{o})(\mathbf{h}_L - \mathbf{h}_R) &= 0 \\ a &= \frac{(\mathbf{s}_R - \mathbf{o})(\mathbf{h}_L - \mathbf{h}_R)}{(\mathbf{s}_L - \mathbf{s}_R)(\mathbf{h}_L - \mathbf{h}_R)} \end{aligned} \quad (3)$$


Ko poznamo s_z , izračunamo k z enačbo (4).

$$\mathbf{k} = \frac{\mathbf{s}_z - \mathbf{o}}{|\mathbf{s}_z - \mathbf{o}|} \quad (4)$$

Končno z enačbo (5) izračunamo i .

$$\mathbf{i} = \mathbf{j} \times \mathbf{k} \quad (5)$$

Preizkusili smo še **telesni koordinatni sistem z referenčno osjo z** . Prikazan je na sliki 2. Izhodišče ima enako kot prvi telesni koordinatni sistem, za os z pa uporablja kar os z referenčnega koordinatnega sistema. Os y je pravokotna na z , leži v ravnini, ki jo določajo H_R , H_L in os z , ter je usmerjena proti levemu kolku. Os x je pravokotna na y in z ter je usmerjena naprej (pri pokončnem položaju telesa).



Slika 2. Telesni koordinatni sistem z referenčno osjo z .

Tudi pri tem koordinatnem sistemu se izhodišče izračuna z enačbo (1). Bazni vektor k je enak baznemu vektorju k v referenčnem koordinatnem sistemu: $k = (0, 0, 1)$. Bazni vektor i je pravokoten na k in na vektor od O do H_L , kar izraža enačba (6).

$$\mathbf{i} = \frac{\mathbf{k} \times (\mathbf{h}_L - \mathbf{o})}{|\mathbf{k} \times (\mathbf{h}_L - \mathbf{o})|} \quad (6)$$

Bazni vektor j pa izračunamo z enačbo (7).

$$\mathbf{j} = \mathbf{k} \times \mathbf{i} \quad (7)$$

Za pretvorbo koordinat iz referenčnega v telesni koordinatni sistem uporabimo enačbo (8). Vektor $\mathbf{p}_R = (x_R, y_R, z_R, 1)$ ustreza točki (x_R, y_R, z_R) v referenčnem koordinatnem sistemu, vektor $\mathbf{p}_B = (x_B, y_B, z_B, 1)$ pa točki (x_B, y_B, z_B) v telesnem. $T_{R \rightarrow B}$ je transformacijske matrika iz referenčnega v telesni koordinatni sistem. Oznaka $i_{(B)R}$

pomeni bazni vektor i telesnega koordinatnega sistema, izražen v referenčnem koordinatnem sistemu.

$$\mathbf{p}_B = \mathbf{T}_{R \rightarrow B} \mathbf{p}_R^T$$

$$\mathbf{T}_{R \rightarrow B} = \begin{bmatrix} x_{i(B)R} & y_{i(B)R} & z_{i(B)R} & -\mathbf{o}_{(B)R} \mathbf{i}_{(B)R} \\ x_{j(B)R} & y_{j(B)R} & z_{j(B)R} & -\mathbf{o}_{(B)R} \mathbf{j}_{(B)R} \\ x_{k(B)R} & y_{k(B)R} & z_{k(B)R} & -\mathbf{o}_{(B)R} \mathbf{k}_{(B)R} \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (8)$$

Atributi v telesnem koordinatnem sistemu (povsem telesnem ali z referenčno osjo z), ki ga označuje spodnji indeks B:

- $(x'_{iB}, y'_{iB}, z'_{iB}) \dots$ koordinate značke i v času t
- $v'_{iB} \dots$ absolutna hitrost značke
- $(\varphi'_{iB}, \theta'_{iB}) \dots$ kota gibanja značke glede na os z in ravnino xz

K gornjim atributom spadajo še atributi, izraženi v referenčnem koordinatnem sistemu, ki opisujejo izhodišče telesnega koordinatnega sistema:

- $z'_{OR} \dots$ koordinata z izhodišča telesnega koordinatnega sistema
- $(\Phi'_{OR}, \Theta'_{OR}) \dots$ usmeritev osi x telesnega koordinatnega sistema glede na os z in ravnino xz
- $v'_{OR} \dots$ absolutna hitrost izhodišča telesnega koordinatnega sistema
- $(\varphi'_{OR}, \theta'_{OR}) \dots$ kota gibanja izhodišča telesnega koordinatnega sistema glede na os z in ravnino xz

Koordinate in izpeljane attribute je v telesnem koordinatnem sistemu mogoče izraziti za vsak položaj telesa posebej, lahko pa vseh N položajev znotraj intervala, ki ga opisuje atributni vektor, izrazimo v telesnem koordinatnem sistemu, ki pripada prvemu položaju v intervalu. Tako lahko zajamemo spremembe koordinat x in y znotraj opazovanega intervala. **Atributi v telesnem koordinatnem sistemu prvega položaja** so enaki atributom v telesnem koordinatnem sistemu, le da jih namesto z indeksom B označujemo z Bf. Nekoliko drugačni pa so pripadajoči atributi v referenčnem koordinatnem sistemu:

- $z_{OR} \dots$ koordinata z izhodišča telesnega koordinatnega sistema prvega položaja
- $(\Phi_{OR}, \Theta_{OR}) \dots$ usmeritev osi x telesnega koordinatnega sistema prvega položaja glede na os z in ravnino xz

3.3 Koti med deli telesa

Podrobnostim izračuna atributov kotov med deli telesa se v prispevku ne bomo posvečali. Koti med deli telesa, ki se ne pregibajo zgolj v eni osi, so izraženi s kvaternioni.

- $\alpha'_{EL}, \alpha'_{ER}, \alpha'_{KL}$ in $\alpha'_{KR} \dots$ koti levega in desnega komolca ter levega in desnega kolena v času t
- q'_{SL} in $q'_{SR} \dots$ kota leve in desne rame glede na zgornji del trupa
- q'_{HL} in $q'_{HR} \dots$ kota levega in desnega kolka glede na spodnji del trupa

- $q'_T \dots$ kot med spodnjim in zgornjim delom trupa

4 POIZKUSI S STROJNIM UČENJEM

Iz posnetkov, opisanih v razdelku 2, smo dobili 5.760 atributnih vektorjev, ki so jih sestavljali atributi, opisani v razdelku 3 (v različnih kombinacijah, tako da jih je bilo med 240 in 2.700). Izbrali smo osem algoritmov za strojno učenje iz paketa Weka. Vse algoritme razen Adaboosta M1 smo pognali s privzetimi nastavitvami. Pri Adaboostu M1 smo za osnovni algoritem vzeli odločitvena drevesa Fast Decision Tree Learner, saj je s privzetimi odločitvenimi štori dajal izredno slabe rezultate. Klasifikacijsko točnost smo izmerili z desetkratnim prečnim preverjanjem, ki smo ga ponovili desetkrat, da smo lahko izračunali statistično pomembnost. Tabela 1 kaže točnosti za vse algoritme in posamične nabore atributov, obravnavane v razdelku 3, za nezašumljene in zašumljene vhodne podatke. Točnost pri najboljših atributih za vsak algoritem je krepka, pri najboljšem algoritmu za vsake attribute pa na sivi podlagi.

Atributi	Nezašumljeni podatki					
	referenčni	telesni	telesni z ref. z	telesni 1. položaja	telesni 1. položaja z ref. z	koti
odločitvena drevesa C4.5	94,1	92,8	93,7	92,9	93,2	91,8
odločitvena pravila RIPPER	93,1	91,4	92,8	92,0	93,0	90,9
naivni Bayes	89,5	88,7	90,6	86,8	88,2	76,7
3-najbližji sosedi	97,1	92,0	82,8	88,1	85,1	96,9
podporni vektorji	97,7	94,4	95,0	94,1	94,3	90,5
naključni gozd	97,0	96,5	96,8	96,0	96,0	96,8
“bagging”	95,9	95,3	95,7	95,4	94,9	94,5
“boosting” Adaboost M1	97,7	94,9	95,3	94,7	94,7	94,4
	Zašumljeni podatki					
odločitvena drevesa C4.5	90,1	88,4	89,9	88,9	90,0	80,8
odločitvena pravila RIPPER	87,5	84,7	88,1	86,2	88,6	80,0
naivni Bayes	83,9	79,1	84,0	81,0	82,2	78,2
3-najbližji sosedi	95,3	74,6	79,7	73,4	74,7	93,3
podporni vektorji	96,3	87,2	91,6	89,9	91,1	87,2
naključni gozd	93,9	90,5	93,4	91,9	93,2	90,5
“bagging”	93,6	91,8	93,3	92,3	93,5	89,1
“boosting” Adaboost M1	93,2	92,0	93,1	92,1	92,9	88,4

Tabela 1. Klasifikacijska točnost za vse algoritme in vse posamične nabore atributov.

Tabela 2 za vsak algoritem kaže število primerjav z drugimi algoritmi, v katerih ima statistično pomembno ($p < 0,05$) večjo klasifikacijsko točnost, zmanjšano za število primerjav, kjer je slabši. Tabela 3 isto kaže za posamične nabore atributov. Rezultati najboljšega algoritma in nabora so krepki, rezultati algoritmov in naborov, s katerimi se bomo ukvarjali v naslednjem koraku, pa na sivi podlagi. Za potrebe kombiniranja naborov atributov smo ohranili attribute v telesnem koordinatnem sistemu brez referenčne osi z. Atributi z referenčno osjo z imajo sicer večjo točnost, a referenčne koordinate z so že vključene v nabor atributov v referenčnih koordinatah. Primerjava med atributi v telesnem koordinatnem sistemu vsakega položaja in prvega položaja je rahlo v prid slednjim, a smo se vseeno odločili za prve, ker so hitreje izračunljivi.

Algoritem	Zmage – porazi	
	Nezašumljeni	Zašumljeni
odločitvena drevesa C4.5	-12	-10
odločitvena pravila RIPPER	-18	-21
naivni Bayes	-38	-34
3-najbližji sosedi	-13	-16
podporni vektorji	13	11
naključni gozd	38	23
“bagging”	17	25
“boosting” Adaboost M1	13	22

Tabela 2. Število zmag – število porazov vsakega algoritma proti drugim.

Atributi	Zmage – porazi	
	Nezašumljeni	Zašumljeni
referenčni	25	28
telesni	-2	-21
telesni z ref. z	9	20
telesni 1. položaja	-11	-9
telesni 1. položaja z ref. z	-2	12
koti	-19	-30

Tabela 3. Število zmag – število porazov vsakega posamičnega nabora atributov proti drugim.

V naslednjem koraku smo preizkusili kombinacije naborov atributov. Tabela 4 kaže klasifikacijske točnosti za štiri algoritme, izbrane v prejšnjem koraku, in kombinacije izbranih naborov atributov za nezašumljene in zašumljene vhodne podatke. Točnost pri najboljših atributih za vsak algoritem je krepka, pri najboljšem algoritmu za vsake attribute pa na sivi podlagi.

5 ZAKLJUČKI IN NADALJNJE DELO

Ugotovili smo, da se med preizkušenimi algoritmi za strojno učenje najbolj obnesejo podporni vektorji, naključni gozd, “bagging” in “boosting” Adaboost M1 (tabela 2). Nekoliko prednjači metoda podpornih vektorjev, ki v kombinaciji z najboljšimi atributi v vseh primerih doseže največjo klasifikacijsko točnost (tabeli 1 in 4). Zaradi rezultatov z atributi v referenčnem koordinatnem sistemu in koti med deli telesa je zanimiva tudi metoda

najbližjih sosedov (tabela 1). Te algoritme bi veljalo preizkusiti še z uglašeni parametri in večjim šumom (kakšen bo šum sistema za določanje položaja v projektu Confidence, ne vemo zanesljivo).

Od atributov se najbolj obnesejo atributi v referenčnem koordinatnem sistemu (tabela 3). Kombinacije naborov atributov so si med seboj podobne (tabela 4) in komaj presežejo posamične nabore atributov. Morda je razlog preveliko število atributov (tudi do 2.700), tako da bi veljalo preizkusiti kako metodo za izbiro atributov.

Atributi	referenčni + telesni	referenčni + telesni z ref. z	referenčni + koti	telesni + koti	telesni z ref. z + koti	vsi	vsi (ref. z)
Nezašumljeni podatki							
podporni vektorji	96,6	96,9	97,7	95,3	95,5	96,7	96,9
naključni gozd	97,0	97,0	97,2	96,7	96,9	97,1	97,0
“bagging”	96,1	96,0	96,1	95,6	95,7	96,3	96,0
“boosting” Adaboost M1	95,7	95,6	95,5	95,3	95,3	95,6	95,5
Zašumljeni podatki							
podporni vektorji	95,5	95,4	96,5	91,9	92,5	95,6	95,5
naključni gozd	93,8	94,2	94,1	91,8	93,5	93,9	94,0
“bagging”	93,8	94,1	93,7	92,4	93,4	93,8	94,1
“boosting” Adaboost M1	93,6	93,7	93,2	93,2	93,3	93,6	93,7

Tabela 4. Klasifikacijska točnost za izbrane algoritme in kombinacije naborov atributov.

Zahvala

Pri programiranju je pomagala Barbara Tvrđi. Raziskave, opisane v prispevku, je financirala Evropska skupnost s Sedmim okvirnim programom pod številko projekta 214986.

Literatura

- [1] Confidence. <http://www.confidence-eu.org/> [2008-09-15]
- [2] eMotion. Smart motion capture system. <http://www.emotion3d.com/smart/smart.html> [2008-09-15]
- [3] Maybeck, P. S. (1979). Stochastic models, estimation, and control. Mathematics in Science and Engineering 141.
- [4] Ubisense. <http://www.ubisense.net/> [2008-09-15]
- [5] Witten, I. H., in Frank, E. (2005). Data Mining: Practical machine learning tools and techniques, 2nd Edition. Morgan Kaufmann, San Francisco, ZDA.