

РАСПОЗНАВАНИЕ ДЕЙСТВИЙ МЕДИЦИНСКИХ РАБОТНИКОВ НА ОСНОВЕ ПОКАЗАТЕЛЕЙ АКСЕЛЕРОМЕТРОВ С ИСПОЛЬЗОВАНИЕМ ГЛУБИННОЙ СЕТИ УБЕЖДЕНИЙ

Аннотация. Исследуется и анализируется реальное множество больших по объему медико-статистических данных, используемых для распознавания действий медицинских работников на основе показателей акселерометров в определенный момент времени. В процессе распознавания применена глубинная сеть убеждений на неразмеченных данных, после чего проведено обучение с учителем методом обратного распространения ошибки. Полученные результаты показали более высокую точность распознавания по сравнению с базовыми методами. Достигнуто также значительное улучшение относительно продолжительности действий медперсонала.

Ключевые слова: глубинная сеть убеждений, акселерометр, глубинная нейронная сеть.

ВВЕДЕНИЕ

На основе последних результатов в области машинного обучения можно утверждать, что эффективная обработка медико-статистических данных большого объема является актуальной задачей относительно оптимизации работы медперсонала. Это важно также для пациентов, поскольку оптимизируется общий процесс ухода за больными, что приводит к снижению затрат и сокращению срока их пребывания в стационаре. В настоящее время исследованы методы распознавания действий медработников с помощью таких специальных датчиков, как акселерометры, гироскопы и низкочастотные аудиоустройства. Однако, несмотря на стремительное развитие указанных методов, некоторые вопросы остаются открытыми. Как правило, при распознавании действий медперсонала классы действий описываются предметно-специфическим образом. Распознавание действий — достаточно сложный процесс, поскольку имеют место признаки, значения которых варьируются даже для отдельных классов. Такие действия имеют определенные дисбалансы: число вхождений среди классов, число начинаний в неделю, продолжительность. Классические подходы предусматривают, что классы действий имеют одинаковые вероятности в произвольный момент времени в течение дня, а также одинаковые длительности. Поэтому методы, точность которых не изменяется при анализе дисбалансов, неизвестны. Исследуя действия медработников, можно определить четкие задачи: эффективное улучшение их функционирования по времени, оптимизация продолжительности процедур, удовлетворенность пациентов, оптимизация затрат на выполнение профессиональных обязанностей сотрудников. Цель технических разработок заключается не только в повышении точности распознавания действий относительно классического определения с применением локальных временных окон, но и в оценке сектора, т.е. диапазона, в котором действия выполняются непрерывно с использованием корректных временных признаков и продолжительности.

ХАРАКТЕРИСТИКА ДАННЫХ ДАТЧИКОВ

Для решения указанных проблем алгоритмы машинного обучения требуют введения реальных данных для их корректной оценки. В рамках исследования отобраны размеченные данные, соответствующие фактическому функционированию медработников, которые имели при себе акселерометры в течение двух недель. Эти данные объединили с учебными признаками. В результате было сформировано 34 класса действий с 7434 метками от 24 сотрудников. Кроме того, отобрали неразмеченные данные — открытые данные большого объема для 73 медработников. (От медперсонала, а также 120 пациентов было получено согласие относительно использования специальных измерительных датчиков и устройств для ведения медицинских записей.)

На основе размеченных данных установлено, что выполняемые процессы имеют определенные дисбалансы в ряде случаев для каждого класса действий, времени начала рабочего дня, а также продолжительности.

Отметим, что данные датчиков получены от сотрудников медицинского учреждения, специализирующегося на исследовании сердечно-сосудистых заболеваний. Множество данных содержит размеченные данные, отобранные в течение двух недель, и неразмеченные данные от 134 пациентов, отобранные в течение двух лет. Для анализа размеченных и неразмеченных множеств данных в процессе проведения экспериментальных исследований медперсонал имел специальные устройства iPod Touch в нагрудных карманах, записывающие ускорения в фиксированном направлении [1]. Кроме того, использовались небольшие акселерометры, один из которых прикреплялся на правом запястье, другой — на спине, в области талии. Каждый датчик измерял ускорение по трем осям в диапазоне $\pm 2G$.

В качестве множества размеченных данных использовались данные по выполнению профессиональных обязанностей 27 медработниками за две недели в декабре 2015 года. Указанные данные размечались с помощью специального устройства другими сотрудниками, наблюдающими за процессом. Перед началом исследования определили 37 классов действий, информация о которых записывалась наблюдателями.

Интерпретация признаков для реальных действий медработников требует тщательной проработки. В их профессиональной деятельности уход за пациентами — приоритетная обязанность, однако в данном случае имеет место проблема отсутствия большинства признаков или наличие неверных признаков времени. Поэтому в качестве наблюдателя был привлечен сотрудник, управляющий другим устройством iPod Touch для записи действий коллег. На устройстве было установлено программное обеспечение, с помощью которого он выбирал класс действий, в рамках которого медработник собирался начать процедуру, и активировал знак окончания, когда она заканчивалась [2, 3].

Когда наблюдатель ожидал начала выполнения процедуры, начальные временные признаки имели соответствующую задержку. Таким образом, он и медперсонал взаимодействовали для получения корректных начальных временных признаков. Перед началом определенной процедуры медработник объявлял об этом наблюдателю.

В том же отделении медицинского учреждения получено множество неразмеченных данных, зафиксированных с помощью датчика в течение двух лет от

медработников, носивших три акселерометра таким же образом, как и для случая размеченных данных.

ОПРЕДЕЛЕНИЕ МНОЖЕСТВА ДАННЫХ

Для использования общего множества данных в качестве размеченных и неразмеченных они были равномерно отформатированы, насколько это возможно. Поскольку идентификаторы для медперсонала последовательные, идентификатор для конкретного медработника одинаков для двух видов данных. Кроме того, каждый датчик, прикрепленный в конкретном месте на теле, сохраняет свои данные отдельно, что позволяет эффективно проводить анализ данных, которые объединяются в одну таблицу из нескольких столбцов. Таким образом, были объединены данные трех устройств, которые отбирались в течение рабочих дней, в одну таблицу. Сначала были сгенерированы признаки времени с увеличением частоты на 24 Гц, что означает 0,06 с, и использована ближайшая выборка данных в момент времени 0,074 с для каждого временного признака [4]. Заметим, что в случае непоступления выборок в течение 0,037 с повторно использовалось последнее значение временных признаков. Поскольку все устройства имеют собственные таймеры и нет взаимодействия по синхронизации времени, существует риск того, что общее время будет несинхронизированным. Для решения этой проблемы таймеры обнуляли одновременно, периодически, в среднем один раз в день, для получения опорной метки времени, после чего использовали относительное время от времени обнуления.

ПОДГОТОВКА ДАННЫХ

Медработники размещали мобильные устройства, записывающие ускорения, в нагрудных карманах в строго фиксированном положении. Каждый сотрудник носил также два акселерометра на правом запястье и пояснице. Каждый датчик измерял ускорение для трех осей. Эти замеры включают размеченные данные за две недели и неразмеченные данные некоторых дежурств за два года. Данные доступны по ссылке: <https://redmine.sozolab.jp/projects/nursing/files>.

В программной реализации использовалась следующая структура файлов и папок.

1. acts.csv: список всех действий.
2. labelled.zip: данные сенсоров трех акселерометров с метками в течение двух недель.
 - 2.1. Labelled:
 - 2.1.1. sensors/#{nurseID}_#{date}_#{start_t}-#{end_t}.csv: данные сенсоров для медицинского работника с ID #{nurseID} в течение времени от #{start_t} (ggxxcc) до #{end_t} (ggxxcc) в день #{date} (PPPPMMDD);
 - 2.1.2. labels/#{nurseID}_#{date}.csv: метки дежурства для медицинского работника с ID #{nurseID} в день #{date} (PPPPMMDD).
 3. unlabelled.zip: неразмеченные данные датчиков с трех акселерометров без меток.
 - 3.1. Unlabelled:
 - 3.1.1. duties.csv: записи дежурств медицинских работников, полученные из информационной системы медицинского учреждения;
 - 3.1.2. sensors/#{duty_id}.csv: данные датчиков для смены #{duty_id} с duties.csv.

В табл. 1 приведен перечень действий acts.csv, которые необходимо распознать. Однако в выборке размеченных данных имеются лишь определенные метки, количество которых подсчитано в файлах из папки Labelled/labels (табл. 2).

Таблица 1. Классы действий acts.csv

action_id	action_name
1	Anamnese (patient sitting)
2	Anamnese (nurse standing)
3	Anamnese (nurse half-sitting)
4	Measure height
5	Measure weight (dorsal)
6	Measure weight (stand)
7	Measure waist
8	Measure blood pressure (dorsal)
9	Measure blood pressure (sit)
10	Sample blood (dorsal)
11	Sample blood (sit)
12	Start intravenous injection
13	Finish intravenous injection
14	Start drip infusion
15	Change drip / line
16	Pull out drip / line
17	Measure blood sugar
18	Assist doctor
19	Find artery
20	Examine edema (lie on back)
21	Examine edema (sit)
22	Check bedsore (sacrum/back heel)
23	Measure ECG
24	Attach ECG
25	Remove ECG
26	Pull out urethral catheter
27	Attach bust bandage
28	Portable X-ray (prone)
29	Changebandage
30	Gatch up
31	Change posture
32	Clean body
33	Assist urinal excretory
34	Assist bedpan excretory
35	Assist portable toilet
36	Assist wheelchair
37	Assist walk
38	Move bed
39	Wash hands
40	Record work (manual)
41	Record work (PC)

Таблица 2. Исследуемые классы действий и число меток

action_id	action_name	Число меток
1	Anamnese (patient sitting)	2
4	Measure height	31
5	Measure weight (dorsal)	13
8	Measure blood pressure (dorsal)	831
10	Sample blood (dorsal)	27
12	Start intravenous injection	103
13	Finish intravenous injection	61
15	Change drip / line	67
18	Assist doctor	26
19	Find artery	361
20	Examine edema (lie on back)	148
22	Check bedsore (sacrum / back heel)	11
23	Measure ECG	30
24	Attach ECG	75
25	Remove ECG	25
27	Attach bust bandage	48
28	Portable X-ray (prone)	7
29	Change bandage	44
31	Change posture	114
32	Clean body	45
36	Assist wheelchair	135
37	Assist walk	43
38	Move bed	28
39	Wash hands	175
41	Record work (PC)	1478
42	Time synchronization (в перечне действий отсутствует)	10

Значения некоторых датчиков в неразмеченных данных могут отсутствовать временно (их значения равны NA) или в течение всего дежурства медперсонала (отсутствие колонок с замерами).

Далее приведен перечень файлов с отсутствующими показателями датчиков в течение смены:

3.csv	38.csv	65.csv	107.csv	129.csv	148.csv	176.csv	205.csv
9.csv	39.csv	69.csv	108.csv	130.csv	151.csv	177.csv	207.csv
10.csv	40.csv	70.csv	109.csv	133.csv	155.csv	180.csv	
12.csv	41.csv	71.csv	110.csv	134.csv	158.csv	181.csv	
13.csv	42.csv	73.csv	111.csv	135.csv	159.csv	182.csv	
16.csv	43.csv	74.csv	112.csv	136.csv	160.csv	183.csv	
17.csv	45.csv	76.csv	113.csv	137.csv	161.csv	184.csv	
18.csv	48.csv	77.csv	114.csv	138.csv	162.csv	185.csv	
19.csv	49.csv	82.csv	115.csv	139.csv	163.csv	186.csv	
21.csv	50.csv	88.csv	116.csv	140.csv	164.csv	187.csv	
22.csv	51.csv	93.csv	117.csv	141.csv	165.csv	188.csv	
25.csv	53.csv	94.csv	118.csv	142.csv	168.csv	189.csv	
26.csv	55.csv	100.csv	119.csv	143.csv	169.csv	190.csv	
28.csv	56.csv	102.csv	120.csv	144.csv	171.csv	191.csv	
32.csv	59.csv	103.csv	122.csv	145.csv	172.csv	196.csv	
33.csv	60.csv	104.csv	126.csv	145.csv	173.csv	200.csv	
36.csv	61.csv	105.csv	127.csv	146.csv	174.csv	202.csv	
37.csv	62.csv	106.csv	128.csv	147.csv	175.csv	203.csv	

Отметим, что файлами дежурств без NA являются: 16.csv, 17.csv, 36.csv, 37.csv, 48.csv, 61.csv, 62.csv, 69.csv, 74.csv, 102.csv, 103.csv, 105.csv, 113.csv, 128.csv, 134.csv, 139.csv, 158.csv, 190.csv. Кроме того, имеются также файлы без соответствующих колонок, т.е. с отсутствующими показателями датчиков в течение смены [5]. Заметим, что выделенные файлы не содержат NA. Это означает, что отсутствует дежурство по полным данным.

Дальнейший подсчет отношения строк со всеми замерами всех датчиков к общему количеству строк показал соответствующие результаты, рассчитанные как отношение суммарного количества строк в файлах данных. Итак, $\frac{7431468}{179712000} = 0,0413521$, т.е. примерно 4% замеров являются полными. Поэтому пустые колонки заполняются, а значения NA заменяются на 0. Таким образом, на масштабирование, которое описано ниже, это не влияет. Отметим, что файл 16.csv оказался пустым и для дальнейшего анализа не используется [6].

Учитывая тот факт, что на вход сети подаются значения с отрезка $[0,1]$, каждую координату входящего вектора признаков необходимо масштабировать на нужный промежуток с помощью преобразования

$$v_{\text{new}} = \frac{v_{\text{old}} - v_{\text{min}}}{v_{\text{max}} - v_{\text{min}}},$$

где v_{new} — новое значение, v_{old} — старое значение, v_{min} — минимальное значение, v_{max} — максимальное значение.

Таблица 3. Минимумы и максимумы замеров для всех измерений x, y, z

Компоненты замеров	Размеченная выборка		Неразмеченная выборка		Результат	
	минимум	максимум	минимум	максимум	v_{min}	v_{max}
chest_x	-2,01225	2,02275	-2,07481	2,05991	-2,07481	2,05991
chest_y	-2,04399	2,06467	-2,08452	2,15492	-2,08452	2,15492
chest_z	-2,06323	2,04384	-2,06635	2,05005	-2,06635	2,05005
waist_x	-2	1,98438	-2	1,984375	-2	1,984375
waist_y	-2	1,98438	-2	1,984375	-2	1,984375
waist_z	-2	1,98438	-2	1,984375	-2	1,984375
right_x	-4	3,96875	-4	4	-4	4
right_y	-4	3,96875	-4	4	-4	4
right_z	-4	3,96875	-4	4	-4	4

Для проведения данной процедуры определены минимумы и максимумы замеров для всех измерений x , y , z каждого акселерометра для размеченных и неразмеченных данных (табл. 3).

СООТВЕТСТВИЕ МЕЖДУ ВРЕМЕНЕМ ВЫПОЛНЕНИЯ ДЕЙСТВИЙ И ЗАМЕРАМИ АКСЕЛЕРОМЕТРОВ

Для этапа обучения необходимы размеченные данные. Поскольку данные являются несогласованными, найдены соответствия между временем выполнения действий и замерами акселерометров. Кроме того, имеют место случаи, когда определенные действия осуществляются параллельно (во время выполнения одного вида деятельности начиналось выполнение другого). В таких ситуациях фиксировались промежутки времени осуществления действия, которое началось раньше, потом определялись замеры датчиков в этих промежутках и соответственно размечались. Если часть данных, которые замерялись во время выполнения другого действия, уже были размечены, то размечались остальные. Например, первое действие имеет временные границы 9:04:16 – 9:04:48, а второе — 9:04:20 – 9:05:45, тогда часть замеров до 9:04:48 размечается соответственно первому действию, а остальные — второму [7]. Если первое действие полностью перекрывает по времени второе, то последнее игнорируется. После данной обработки было подсчитано количество замеров для каждого действия: всего 8 246 731 (табл. 4).

Таблица 4. Число замеров для каждого действия

action_id	action_name	Число замеров датчиков	Процент общего числа замеров
1	Anamnese (patient sitting)	3300	0,04001586
4	Measure height	17338	0,21024088
5	Measure weight (dorsal)	49458	0,59972855
8	Measure blood pressure (dorsal)	1399086	16,9653406
10	Sample blood (dorsal)	120935	1,46645986
12	Start intravenous injection	179677	2,17876635
13	Finish intravenous injection	81294	0,98577242
15	Change drip / line	316864	3,84229824
18	Assist doctor	87566	1,0618268
19	Find artery	136524	1,65549234
20	Examine edema (lie on back)	20284	0,24596413
22	Check bedsore (sacrum / back heel)	27481	0,33323507
23	Measure ECG	67461	0,81803323
24	Attach ECG	81541	0,98876755
25	Remove ECG	1880	0,02279691
27	Attach bust bandage	15638	0,18962665
28	Portable X-ray (prone)	9940	0,12053261
29	Changebandage	62445	0,75720913
31	Change posture	302704	3,67059384
32	Clean body	397420	4,81912166
36	Assist wheelchair	471352	5,71562235
37	Assist walk	38604	0,46811276
38	Move bed	65941	0,79960168
39	Wash hands	87229	1,05774033
41	Record work (PC)	4203467	50,9713121
42	Time synchronization (в перечне действий отсутствует)	1302	0,01578807

Для учебной выборки отобрано по 1000 первых замеров каждого действия (в общем — 26 000 показателей), которые подавались на вход алгоритма случайным образом.

ГЛУБИННАЯ СЕТЬ УБЕЖДЕНИЙ

Для обработки полученных в результате анализа данных использовалась глубинная сеть убеждений, состоящая из определенного числа ограниченных машин Больцмана, в которых скрытый слой каждой подсети служит видимым слоем для следующей. Глубинная сеть убеждений может быть «жадно» обучена слоем за слоем, что способствует быстрому обучению данной модели [8].

Пусть X — матрица входов, рассматриваемая в качестве множества векторов признаков. Алгоритм обучения глубинной сети убеждений включает следующие шаги.

1. Провести обучение ограниченной машины Больцмана на X для получения матрицы ее весовых коэффициентов W . Матрицу весов использовать как матрицу весовых коэффициентов между двумя нижними слоями сети.

2. Преобразовать X для получения новых данных X' с помощью ограниченной машины Больцмана, используя выборку данных или среднюю активацию скрытых узлов.

3. Повторить данную процедуру с $X \leftarrow X'$ для следующей пары слоев, пока не будет достигнуто двух верхних слоев сети.

Для обучения ограниченной машины Больцмана использован одношаговый алгоритм сравнительного расхождения, состоящий из следующих шагов.

1. Принять учебный образец v , вычислить вероятности скрытых узлов, а также выбрать вектор скрытой активации h из распределения вероятностей.

2. Вычислить внешнее произведение v и h , являющееся положительным градиентом.

3. С учетом значения h выбрать восстановление видимых узлов v' , затем из него выбрать скрытые активации h' (шаг выборки по Гиббсу).

4. Вычислить внешнее произведение v' и h' , являющееся отрицательным градиентом.

5. Определить уточнением $w_{i,j}$ разницу положительного и отрицательного градиентов, умноженную на определенный темп обучения, а именно: $\Delta w_{i,j} = \varepsilon(vh^T - v'h'^T)$.

После обучения модели по данному алгоритму на полученной сети был применен метод обратного распространения ошибки для улучшения результатов.

МНОГОСЛОЙНАЯ НЕЙРОННАЯ СЕТЬ

Для обработки данных использовалась классическая многослойная нейронная сеть, которая обучается с помощью метода обратного распространения ошибки. Сеть не может иметь менее двух слоев (входящего и исходящего) и менее одного нейрона в одном слое. Ограничения на количество скрытых слоев определяется только объемом оперативной памяти. Кроме того, была предоставлена возможность вручную устанавливать веса и смещение для каждого слоя, а также получать значения весов каждого слоя сети.

В качестве активационной функции нейронов использовалась сигмоидная функция $f(x) = \frac{1}{1 + e^{-x}}$ с производной $f'(x) = f(x)(1 - f(x))$. Алгоритм классификации данных с применением нейронной сети включает следующие шаги.

1. Определить вектор входных значений $x = (x_1, x_2, \dots, x_n)$ и установить их в качестве исходных значений входного слоя сети.

2. Для каждого слоя сети, по очереди, начиная с первого за входным слоем:

а) подать к сумматору каждого нейрона выходные значения предыдущего слоя;

- б) получить результат сумматора $sum = \sum_i^n weight[i] \cdot input[i]$;
- в) добавить смещение $sum = sum + bias$;
- г) пропустить результат предыдущих действий через активационную функцию и получить исходное значение нейрона $out = f(sum)$.

3. Среди исходных значений выходного слоя определить максимальное и вернуть индекс нейрона, соответствующий максимальному значению. Это и будет классом, к которому сеть отнесла данные $c = \arg \max_i (out_i)$.

В результате классификации данных применен следующий алгоритм обучения нейронной сети.

1. Получить на вход обучающую выборку и правильные ответы к ней.
2. Для каждого $i \in [1, n]$, где n — число эпох, выполнить такие действия:
 - а) случайным образом из обучающей выборки принять входные данные $input = (inp_1, inp_2, \dots, inp_n)$ и соответствующий им верный ответ $target = (t_1, t_2, \dots, t_m)$;
 - б) классифицировать $input$, как описано выше, и получить исходные значения сети $output = (out_1, out_2, \dots, out_m)$;
 - в) каждый нейрон k выходного слоя вычисляет такие величины:
 - ошибку $\sigma_k = (t_k - out_k) \cdot f'(sum_k)$,
 - величины, на которые изменяются веса $\Delta w_{jk} = \alpha \cdot \sigma_k \cdot x_j$, где w_{jk} — вес между нейроном j предыдущего слоя и нейроном k выходного слоя, α — параметр скорости обучения, x_j — исходное значение нейрона j предыдущего слоя,
 - изменения сдвига $bias_k = \alpha \cdot \sigma_k$;
 - г) для каждого нейрона q скрытого слоя l , начиная с последнего перед выходным, вычисляем:

- входную ошибку $\sigma_{in} = \sum_{k=1}^n \sigma_k \cdot w_{qk}$, где σ_k — ошибка нейрона k для слоя $(l+1)$, w_{qk} — вес между нейроном q данного слоя и нейроном k для слоя $(l+1)$,
- общую ошибку $\sigma_q = \sigma_{in} \cdot f'(sum_q)$,
- величины, на которые изменяются веса $\Delta w_{jq} = \alpha \cdot \sigma_q \cdot x_j$,
- значение изменения сдвига $bias_q = \alpha \cdot \sigma_q$;
- д) обновить веса каждого нейрона q скрытого слоя $w_{jq}(\text{new}) = w_{jq}(\text{old}) + \Delta w_{jq}$, где $w_{jq}(\text{new})$ — новое значение веса между нейроном q данного слоя и нейроном j предыдущего слоя, а $w_{jq}(\text{old})$ — прежнее значение веса;
- е) обновить веса исходного слоя $w_{jk}(\text{new}) = w_{jk}(\text{old}) + \Delta w_{jk}$, где $w_{jk}(\text{new})$ — новое значение веса между нейроном k выходного слоя и нейроном j предыдущего слоя, а $w_{jk}(\text{old})$ — прежнее значение веса.

ЗАКЛЮЧЕНИЕ

В процессе распознавания данных исследованы две модели: глубинная сеть убеждений и глубинная нейронная сеть. Обучение глубинной сети убеждений проводилось сначала на неразмеченных данных, после чего в глубинной сети убеждений, которая, по сути, является глубинной нейронной сетью с инициализированными особым образом весами связей нейронов, проводилось обучение с учителем методом обратного распространения ошибки. Наиболее высокая точность, которой удалось достичь с использованием данной модели, составила 10,211538%.

Обучение глубинной нейронной сети, в которой веса были инициализированы случайным образом, при использовании метода обратного распространения ошибки, а также без предварительного неконтролируемого обучения продемонстрировало максимальную точность 52,011538%. Поскольку распознавание действий в области медицинского обслуживания является новой и сложной задачей, конкретных требований относительно необходимой точности результатов не существует. Однако, учитывая сложность проведенных вычислений, можно утверждать, что получен-

ные результаты по точности и продолжительности действий могут быть использованы на практике для оптимального функционирования медперсонала.

СПИСОК ЛИТЕРАТУРЫ

1. Dietterich T. Machine learning for sequential data: A review // Structural, syntactic, and statistical pattern recognition. — 2002. — P. 1–15.
2. Tentori M., Favela J. Monitoring behavioral patterns in hospitals through activity-aware computing // Second Intern. Conf. on Pervasive Computing Technologies for Healthcare. — 2008. — P. 173–176.
3. Wang D., Lu L., Zhang H.-J. Speech segmentation without speech recognition // IEEE Intern. Conf. on Acoustics, Speech, and Signal Processing (ICASSP'03). — 2003. — 1. — P. 468–471.
4. Vinh L.T., Lee S., Le H.X., Ngo H.Q., Kim H.I., Han M., Lee Y.K. Semi-Markov conditional random fields for accelerometer-based activity recognition // Applied Intelligence. — 2011. — 35. — P. 226–241.
5. Vail D., Veloso M., Lafferty J. Conditional random fields for activity recognition // Proc. of the 6th Intern. Joint Conf. on Autonomous Agents and Multi Agent Systems. — 2007. — 5. — P. 1–8.
6. Panella M., Marchisio S., Di Stanislao F. Reducing clinical variations with clinical pathways: Do pathways work? // Intern. Journal for Quality in Health Care. — 2003. — 15. — P. 509–521.
7. Naya F., Ohmura R., Takayanagi F., Noma H., Kogure K. Workers' routine activity recognition using body movements and location information // 10th IEEE Intern. Symp. on Wearable Computers. — 2006. — P. 105–108.
8. Mannini A., Sabatini A.M. Machine learning methods for classifying human physical activity from on-body accelerometers // Sensors. — 2010. — 10. — P. 1154–1175.

Надійшла до редакції 15.06.2016

О.А. Галкін

РОЗПІЗНАВАННЯ ДІЙ МЕДИЧНИХ ПРАЦІВНИКІВ НА ОСНОВІ ПОКАЗНИКІВ АКСЕЛЕРОМЕТРІВ З ВИКОРИСТАННЯМ ГЛИБИНОЇ МЕРЕЖІ ПЕРЕКОНАНЬ

Анотація. Досліджується та аналізується реальна множина великих за обсягом медико-статистичних даних, що використовуються для розпізнавання дій медичних працівників на основі показників акселерометрів у визначений момент часу. У процесі розпізнавання застосовано глибинну мережу переконань на нерозмічених даних, після чого проведено навчання з учителем методом зворотного поширення помилки. Отримані результати показали більш високу точність розпізнавання у порівнянні з базовими методами. Досягнуто також значне покращення відносно тривалості дій медперсоналу.

Ключові слова: глибинна мережа переконань, акселерометр, глибинна нейронна мережа.

O.A. Galkin

RECOGNITION OF ACTIONS OF MEDICAL WORKERS ON THE BASIS OF READINGS OF ACCELEROMETERS USING A DEEP BELIEF NETWORK

Abstract. The paper analyzes the real set of large-volume medical and statistical data to be used for recognition of actions of medical workers on the basis of readings of accelerometers at a particular moment of time. During the recognition, deep belief network is applied on unlabeled data, and then trained with supervised learning by backward propagation of errors. The obtained results show a higher recognition accuracy as compared with the basic methods. A significant improvement is achieved as to the duration of actions of medical staff.

Keywords: deep belief network, accelerometer, deep neural network.

Галкін Олександр Анатольевич,
кандидат фіз.-мат. наук, асистент кафедри Київського національного університета імені Тараса Шевченка, e-mail: galkin.o.a@gmail.com.