


Московский государственный университет имени М. В. Ломоносова



Факультет Вычислительной Математики и Кибернетики

Кафедра Математических Методов Прогнозирования

ДИПЛОМНАЯ РАБОТА СТУДЕНТА 517 ГРУППЫ

«Анализ сигналов сенсорных устройств»

Выполнил:

студент 5 курса 517 группы

Остапец Андрей Александрович

Научный руководитель:

д.ф.-м.н., профессор

Дьяконов Александр Геннадьевич

Содержание

1	Введение	3
1.1	Сенсоры	3
1.2	Общая схема работы с сенсорами	4
2	Постановка задачи и описание данных	4
3	Очистка данных от шума	7
3.1	Скользящее среднее	7
3.2	Фильтр нижних частот	8
3.3	Удаление неинформативных участков	10
4	Выделение признаков	11
4.1	Проекция на вертикальную ось и горизонтальную плоскость	11
4.2	Jerk-filter	13
4.3	Признаки от акселерометра	16
4.4	Признаки от гироскопа	18
5	Отбор признаков	19
5.1	Random Forest	19
5.2	LDA	20
6	Вычислительные эксперименты	22
6.1	Условия экспериментов	22
6.2	Методы оценки качества решения	23
6.3	Распознавание по данным от акселерометра	24
6.4	Распознавание по данным от акселерометра и гироскопа	31
7	Выводы	37
8	Заключение	37
	Список литературы	38

Аннотация

Данная работа посвящена использованию методов машинного обучения в задаче определения местоположения телефона. Решение этой проблемы производилось по данным от двух сенсоров – акселерометра и гироскопа.

В рамках поставленной задачи были рассмотрены различные методы очистки сигналов от шума, которые позволяют уменьшить зависимость качества решения от погрешностей измерительных устройств. Также были описаны основные виды признаков, которые используются при работах с сигналами от сенсоров. На реальных данных среди них производился отбор и выделялись лучшие.

Для решения поставленной задачи определения местоположения телефона были реализованы несколько различных методов распознавания. Они были протестированы на реальных данных. В работе представлено экспериментальное исследование и сравнительный анализ алгоритмов. Используя полученные результаты, можно модифицировать методы решения задачи и улучшить их производительность.

1 Введение

1.1 Сенсоры

Современные мобильные устройства обладают не только мощными вычислительными характеристиками, но и разнообразием различного рода датчиков, позволяющих узнать как некоторые свойства текущей среды, так и некоторые свойства самого устройства в этой среде. Для определения характеристик устройства в пространстве в большинстве случаев используются два датчика, установленных на большинстве современных мобильных устройств – это акселерометр и гироскоп (датчик угловой скорости). Гироскоп позволяет определить ориентацию и наклон устройства в пространстве. Изменение положения устройства позволяет определить первый упомянутый датчик — акселерометр.

С развитием технологий акселерометром и гироскопом стали оснащаться практически все мобильные устройства.

Основным назначением акселерометра является предоставление информации о текущем ускорении устройства, вернее разности ускорения устройства и ускорения свободного падения. В состоянии покоя показания датчика совпадают с вектором ускорения свободного падения. В условиях невесомости истинное ускорение объекта вызывается лишь гравитационной силой и потому в точности равно гравитационному ускорению. Таким образом, кажущееся ускорение отсутствует и показания любого акселерометра равны нулю.

Гироскоп измеряет угловую скорость. Обычно используется совместно с акселерометром для отслеживания изменений в движениях. В электронных устройствах программное обеспечение, используемое вместе с гироскопом, способно быстро реагировать на перемещение устройства в пространстве и принимать соответствующие решения. Например, в ноутбуках гироскоп позволяет быстро включить режим фиксации жесткого диска в случае падения или просто резкого перемещения устройства. В мобильных устройствах используются датчики угловой скорости. Этот тип гироскопов является намного более простым и дешёвым при достаточно высокой точности.

1.2 Общая схема работы с сенсорами

Представим общую схему работы с сигналами от сенсорных устройств (подробно принципы работы с сенсорами описаны в статьях [1] и [2]):

- Очистка от шума. Этот этап является необходимым – приборы обладают ограниченной точностью. Помимо этого у разных сенсоров может быть различная калибровка.
- Выделение признаков. На этом этапе стараются выделить признаки, значения которых отличаются у объектов разных классов. Если разрабатывается алгоритм для классификации в реальном времени, то желательно вычислять простые признаки, поскольку существуют ограничения на вычислительную мощность и время работы алгоритма.
- Отбор признаков. В реальной задаче часто получается, что лишних признаков оказывается существенно больше, чем полезных. Попытка построить зависимость из шума может только ухудшить качество алгоритма. Методы обучения должны отличать шумовые признаки от информативных и отбрасывать их.
- Подбор алгоритма классификации. Нужно выбрать алгоритм, который показывает высокое качество и при этом является не слишком вычислительно затратным. Оценки качества алгоритмов для данной задачи подробно описаны в работе [3].

2 Постановка задачи и описание данных

В рамках данной работы ставилась задача исследования возможности определения местоположения мобильного устройства с помощью данных акселерометра и гироскопа. Было выделено 4 основных месторасположения телефона: рюкзак(backpack), сумка(bag), карман(pocket), рука(hand). Каких-либо ограничений на ориентацию устройства в пространстве не ставилось – в любом месторасположении телефон может находиться в произвольной ориентации.




Рис. 1: Пример данных акселерометра

Данные, на которых проводились эксперименты:

- Набор данных, которые были собраны в компании Nokia. Эти данные содержат результаты измерений для 9 человек. Все люди осуществляли одинаковые действия - ходили по одной лестнице вверх и вниз.
- Набор данных Walk Detection and Step Counting on Unconstrained Smartphones [4], который содержит измерения для 27 человек. Каждый участник проходил одну и ту же дистанцию. Подробное описание данных содержится в статье [5]. В Табл. 1 приведена статистика о пользователях из этого набора данных.

Частота дискретизации сигналов для всех наборов данных равна 100 Гц. В среднем, для каждого человека присутствуют 3 различных месторасположения телефона.




Рис. 2: Пример данных гироскопа

Таблица 1: Статистика о пользователях из второго набора данных

Таблица 2: Пол

Мужчин	18
Женщин	9

Таблица 3: Возраст

15-19	9
20-29	18

Таблица 4: Рост[см]

150-159	3
160-169	5
170-179	11
180-189	8

Информация собиралась с помощью разных устройств (Nokia Lumia 720, Samsung Galaxy, ...). Для некоторых данных (например, для тех которые получены с помощью Lumia 720), отсутствуют показания гироскопа.

3 Очистка данных от шума

Показания акселерометра и гироскопа на мобильных устройствах подвержены достаточно сильному шуму. Например, погрешность показаний акселерометра иногда достигает 0.05g, вследствие чего необходима борьба с шумом. Ниже будет рассмотрено несколько подходов к сглаживанию и фильтрации данных. На Рис. 3 приведены измерения акселерометра по одной из осей.




Рис. 3: Показания акселерометра

3.1 Скользящее среднее

Метод средних значений (Moving average, MA) один из самых простых методов фильтрации шума. Алгоритм очень простой: на каждом шаге k , значение v_k вычисляется как среднее из n предыдущих значений акселерометра, то есть $v_k = \frac{\sum_{i=0}^{n-1} a_{k-i}}{n}$. Для значений сигнала имеющих номер $k < n - 1$ значение $v_k = \frac{\sum_{i=0}^k a_{k-i}}{k}$. Такой метод

дает, при средних значениях n , неплохое сглаживание, но имеет один существенный недостаток – достаточно большую задержку в значениях.

Данный метод иногда применяется при работе с сигналами, поскольку является простым. На Рис. 4 представлены примеры фильтров порядков 5 и 20. Примеры применения данного метода представлены в статьях [6] и [7] для задачи определения активности пользователей.




Рис. 4: Применение скользящего среднего для сглаживания сигнала

3.2 Фильтр нижних частот

Фильтры нижних частот – это группа фильтров основной особенностью которых является способность фильтровать сигналы выше указанной частоты, то есть такие фильтры пропускают сигналы низкой частоты, что позволяет избавиться от шумовых помех сигнала.

Самый простой фильтр нижних частот описывается следующей формулой: $O_n = O_{n-1} + \alpha(I_n - O_{n-1})$, где O_n – выходное значение сигнала (отфильтрованное), I_n – входное значение (неотфильтрованное), α – коэффициент фильтрации, принимающий значения от 0 до 1. При α равном 1, выходные значения совпадают с входными. В качестве примера, ниже приводятся два варианта отфильтрованных с помощью фильтра нижних частот данных с коэффициентом $\alpha = 0.2$ и $\alpha = 0.05$, соответственно.




Рис. 5: Применение фильтра нижних частот для фильтрации сигнала

Как видно из примеров меньший коэффициент дает более гладкий результат. Получающийся в результате сигнал достаточно гладкий, но, так же как и при сглаживании методом скользящего среднего, присутствует некоторая задержка, особенно при резком колебании значений. Фильтр нижних частот подавляет сигналы выше некоторой критической частоты w и пропускает сигналы ниже этой частоты.

Этот метод является классическим методом очистки сигналов от шума. Он применяется во многих задачах (например, [8], [9]) и показывает хорошие результаты.

Существуют и другие подходы к решению данной проблемы (например, фильтр Калмана[10]).

3.3 Удаление неинформативных участков

Помимо погрешностей в показаниях сенсоров существует проблема с неоднородностью деятельности человека при сборе данных. Например, на Рис. 6 представлены показания акселерометра при ходьбе человека по лестнице вверх и вниз. Участок в середине наблюдения соответствует остановке и смене направления движения. Для многих задач распознавания такой участок будет только мешать решению, особенно, когда обучение и классификация происходит на небольших участках сигнала – окнах.




Рис. 6: Пример сигнала акселерометра за длительный промежуток времени

В рамках данной задачи было принято решение удалять данные участки, поскольку они не несут никакой полезной информации.



Рис. 7: Ориентации телефона




Рис. 8: Соответствующие показания акселерометра при ходьбе

4 Выделение признаков

При решении задач с сенсорами основная задача – это поиск хороших признаков. Даже при небольшом изменении ориентации телефона в пространстве сигналы получаемые от сенсоров могут сильно измениться. На Рис. 7 изображены 2 возможные ориентации телефона в пространстве, а на Рис. 8 соответствующие показания акселерометра. Как видно из рисунков в результате смены ориентации телефона сигналы акселерометра сильно изменились, хотя поменялась только ориентация телефона в пространстве. В данной работе исследуется вопрос определения местоположения телефона при отсутствии каких-либо ограничений на ориентацию телефона в пространстве. Поэтому особенно важно найти хорошие признаки, которые не зависят или хотя бы минимизируют влияние ориентации телефона в пространстве.

4.1 Проекция на вертикальную ось и горизонтальную плоскость

Для уменьшения влияния ориентации телефона разложим исходный сигнал акселерометра на 2 составляющих – вертикальную и горизонтальную компоненты.

Оценка вектора силы тяжести может быть получена путем усреднения показаний акселерометра. Это оценка вектора гравитации в свою очередь, позволяет оценить

вертикальную составляющую и величину горизонтальной составляющей движения пользователя, независимо от того, как ориентированы оси акселерометра.

Есть две соответствующих друг другу системы координат, как показано на Рис. 9. Акселерометр находится в некоторой произвольной ориентации относительно тела пользователя. Три оси акселерометра обозначены на рисунке как x , y , z . В идеале, хотелось бы извлечь информацию об ускорении с точки зрения системы координат, сопоставленной с движением человека.




Рис. 9: Координатные системы

На рисунке эти оси обозначены v (вертикальная ось), f (движение вперед), и ортогональная направлению движения ось s , которая представляет меньший интерес.

Для наблюдений акселерометра получаем оценку вектора силы тяжести на каждую ось путем усреднения всех показаний акселерометра на эту ось. Фактически, мы оцениваем вертикальный вектор ускорения v соответствующей вектору силы тяжести как $v = (v_x, v_y, v_z)$, где v_x, v_y и v_z являются средними значениями всех измерений интервала дискретизации на соответствующие оси.

Обозначим через $\mathbf{a} = (a_x, a_y, a_z)$ вектор, который является одним измерением внутри окна. Тогда через $\mathbf{d} = (d_x, d_y, d_z)$ обозначим динамическую компоненту, которая вызвана движения пользователя, а не гравитацией. Затем, с помощью скалярного произведения, можно вычислить проекцию \mathbf{p} вектора \mathbf{d} на вертикальную ось \mathbf{v} : $\mathbf{p} = \left(\frac{\mathbf{d} \cdot \mathbf{v}}{\mathbf{v} \cdot \mathbf{v}}\right) \mathbf{v}$.

Далее, так как вектор является суммой своих вертикальной и горизонтальной компонент, можно вычислить горизонтальную составляющую динамического ускорения путем вычитания векторов $\mathbf{h} = \mathbf{d} - \mathbf{p}$.

Однако, в отличие от вертикального случая, мы не знаем ориентацию горизонтальной оси \mathbf{h} относительно оси \mathbf{f} . На самом деле ее и невозможно обнаружить. Там нет статического ускорения, которое присутствует в вертикальном случае.

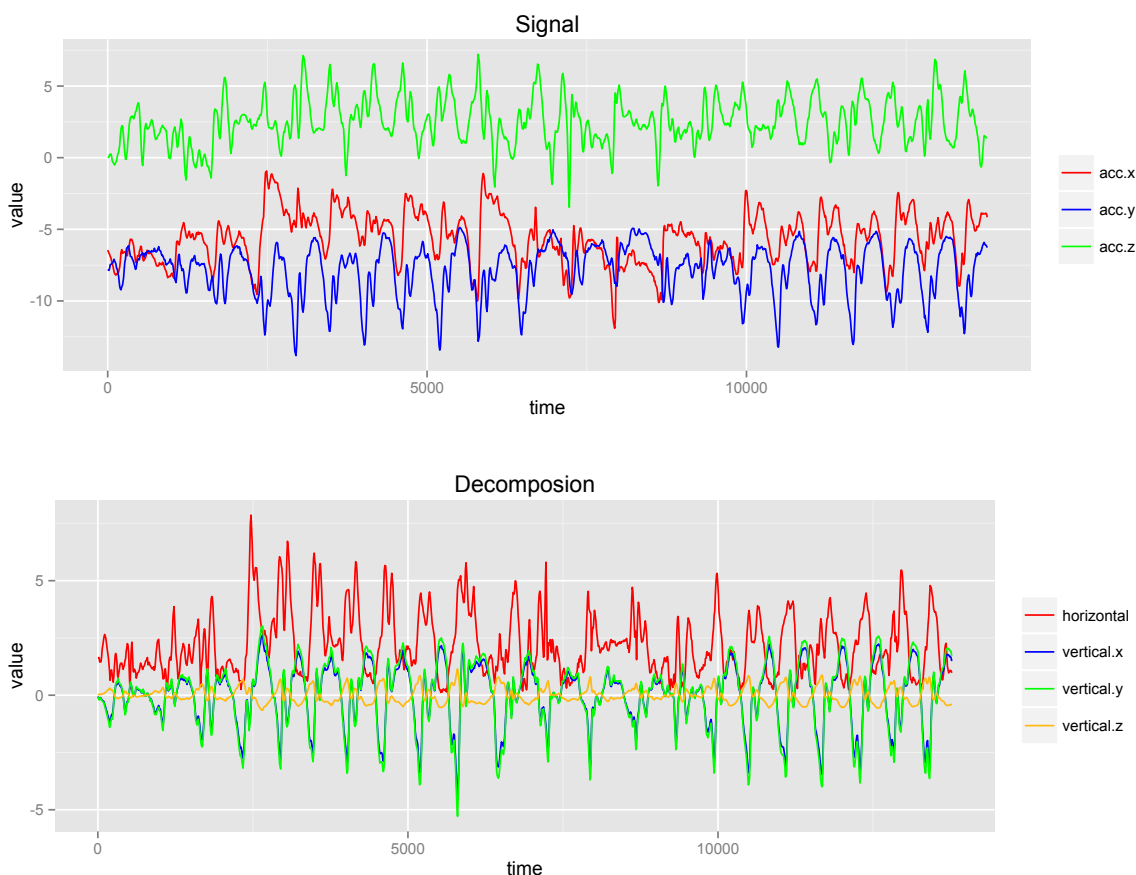


Рис. 10: Разложение сигнала акселерометра на проекции на вертикальную ось и горизонтальную плоскость

Соответственно, можно вычислить общее ускорение на горизонтальную плоскость составляющей динамического ускорения, поскольку это лучшее, что можно сделать в данном случае.

Более сложные методы разложения на горизонтальную и вертикальную проекции приводятся в статье [11].

4.2 Jerk-filter

Как уже отмечалось ранее, основной проблемой при работе с сигналами акселерометра является отсутствие информации об ориентации осей акселерометра. Поэтому нельзя отделить ускорение, вызванное деятельностью человека от ускорения силы тяжести и определить направления наблюдаемых ускорений точно. В качестве одно-

го из решений рассматривается переход к новому каналу, где анализируется изменение ускорений вместо оригинального сигнала ускорения. Общая величина изменения ускорения является полностью независимой от ориентации и отражает ускорение, которое связано только с движением человека. Если направление гравитации может быть аппроксимировано хотя бы приблизительно, то такой канал может дать ценную информацию о изменениях направления движения.




Рис. 11: Вычисление jerk-фильтра

В идеальном случае все измерения ускорения акселерометром \vec{a} зависят от двух компонент: гравитационного ускорения \vec{g} и ускорения \vec{b} , которое связано с движением человека: $\vec{a} = \vec{g} + \vec{b}$. Идея jerk-фильтра состоит в рассмотрении рывков (изменений ускорения) вместо самого ускорения. Этот подход дает возможность получить признаки не зависящие от ориентации телефона без необходимости оценки вектора гравитации точно.

Базовая идея метода показана на Рис. 11. Из двух последовательных ускорений \vec{a}_{i-1} и \vec{a}_i мы составляем вектор их разности $\vec{c}_i = \vec{a}_{i-1} - \vec{a}_i$. Это соответствует среднему рывку на временном интервале $[t_{i-1}, t_i]$. Предполагая, что ориентация телефона телефона не изменилась на этом временном отрезке, получаем, что гравитационная компонента одинакова на этих двух временных шагах, т.е $\vec{g}_{i-1} = \vec{g}_i$. Тогда $\vec{c}_i = \vec{b}_i - \vec{b}_{i-1}$ и получаем разницу без учета вектора \vec{g} . Дополнительно получаем независимость от ориентации телефона величины ускорения вектора \vec{c}_i .




Рис. 12: Пример вычисления jerk-фильтра

Другой полезной особенностью такого метода является возможность оценить угол изменения направления движения. Обозначим данный угол (между векторами \vec{b}_i и \vec{b}_{i-1}) за $\vec{\alpha}_i$. Этот угол также не зависит от ориентации телефона, но точность его оценки сильно зависит от точности оценки вектора \vec{g} . Одна из простых вариантов оценки вектора \vec{g} :

- Взять средние значения по каждой из осей ($\bar{x}, \bar{y}, \bar{z}$)
- Взять значения медиан для каждой из осей ($\text{median}(x), \text{median}(y), \text{median}(z)$)

Другие подходы к оценки вектора \vec{g} приводятся в [12].

Одним из примеров применения jerk-фильтра является фильтр, приведенный в работе [13]. Он определяется следующей функцией:

$$f(c_i, \alpha_i) = \left(1 + \frac{|\alpha_i|}{180}\right) c'_i,$$

где

$$c'_i = \begin{cases} |\vec{c}_i|, & \text{если } |\vec{a}_i| \geq |\vec{a}_{i-1}| \\ -|\vec{c}_i|, & \text{иначе.} \end{cases}$$

Здесь c'_i является величиной вектора изменения ускорения, знак которого показывает увеличилось ускорение или уменьшилось. Угол α_i измеряется в градусах и принимает значения в интервале $[-180, 180]$. Поскольку оценка углов изменения направления является менее точной, чем величина рывка, то оценка угла используется только для модификации. Если направление не изменилось, то $f(c_i, \alpha_i)$ является просто разностью векторов c_i . Чем больше изменяется направление, тем больший коэффициент стоит при этой разности.

4.3 Признаки от акселерометра

Опишем основные признаки, которые применяются при работе с сигналами сенсоров, а также те признаки, которые были выбраны специально для данной задачи.

Первая группа признаков, которые включает в себя стандартные статистические характеристики сигнала:

1. Среднее значение: $\bar{x} = \frac{1}{T} \sum_{i=1}^T x_i$
2. Стандартное отклонение: $s^2 = \frac{1}{T-1} \sum_{i=1}^T (x_i - \bar{x})^2$
3. Минимум, максимум
4. Выборочные квантили порядка 0.10, 0.25, 0.50, 0.75, 0.90.

Пусть задана простая выборка $x^m = (x_1, \dots, x_m)$, и её вариационный ряд есть $x^{(1)} \leq x^{(2)} \leq \dots \leq x^{(m)}$.

Выборочный α -квантиль или выборочный квантиль порядка α , $\alpha \in (0, 1)$, есть статистика, равная элементу вариационного ряда с номером $[m\alpha + 1]$.

5. Сумма и сумма квадратов наблюдений, которые находятся ниже/выше определенных квантилей (0.05, 0.10, 0.25, 0.75, 0.90, 0.95)
6. Попарные разности между квантилями порядка 0.05, 0.10, 0.25, 0.50, 0.75, 0.90, 0.95)
7. Коэффициент асимметрии(Skewness) = $\frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3}{\left(\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2\right)^{3/2}}$
8. Коэффициент эксцесса(Kurtosis) = $\frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4}{\left(\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2\right)^2} - 3$

Эту группу признаков мы можем извлекать из любого канала.

Вторая группа – это часто использующиеся признаки при работе с сигналами, но для их вычисления нужно показания от трех осей x, y, z :

1. Magnitude Mean Value = $\sqrt{\bar{x}^2 + \bar{y}^2 + \bar{z}^2}$
2. Signal Magnitude Area = $\frac{1}{T} \sum_{i=1}^T |x_i| + |y_i| + |z_i|$
3. Average Absolute Difference = $\frac{1}{T} \sum_{i=1}^T |s_i - \bar{s}|$, где $s_i = \sqrt{x_i^2 + y_i^2 + z_i^2}$

Третья группа – это признаки, заимствованные из анализа EEG сигналов. Впервые были представлены в статье [14]. Для начала введем некоторые вспомогательные обозначения:

$$m_0 = \frac{1}{T} \int_{t-T}^t f^2(t) dt, m_1 = \frac{1}{T} \int_{t-T}^t \left(\frac{df}{dt}\right)^2 dt, m_2 = \frac{1}{T} \int_{t-T}^t \left(\frac{d^2f}{dt^2}\right)^2 dt$$

Отсюда можем вычислить следующие характеристики:

- Activity = m_0 , которая равна квадрату стандартного отклонения амплитуды. Иногда эту величину называют еще средней мощностью.
- Mobility = $\sqrt{\frac{m_1}{m_0}}$, которая равна стандартному отклонению мощности спектра.
- Complexity = $\frac{\sqrt{\frac{m_2}{m_1}}}{\sqrt{\frac{m_1}{m_0}}}$, которая показывает неравномерность частотного диапазона.

Четвертая группа признаков основана на использовании числа пересечений сигналом определенных значений (crossing rate). Вычисляется эта характеристика для произвольного сигнала $\{s(t), t = 0, \dots, T\}$ следующим образом:

$$zcr = \sum_{t=1}^{T-1} \mathbb{I} \{s'_t s'_{t-1} < 0\},$$

где $s'(t)$ - сигнал, полученный после вычитания из исходного сигнала значения соответствующего квантиля.

Пятая группа – это признаки, состоящие из различных коэффициентов авторегрессии. К ним относятся статистика Дарбина-Уотсона (Durbin-Watson autocorrelation)[15], максимальное значение корреляции, период автокорреляции[16]. Статистика Дарбина-Уотсона рассчитывается по следующей формуле:

$$DWA = \begin{cases} \frac{\sum_{t=2}^T (s_t - s_{t-1})^2}{\sum_{t=1}^T s_t^2} & \text{если } \sum_{t=1}^T s_t^2 \neq 0, \\ 0, & \text{иначе.} \end{cases}$$

Шестая группа признаков включает себя корреляции между различными каналами. Коэффициент корреляции рассчитывается по формуле:

$$r_{XY} = \frac{\sum (X - \bar{X})(Y - \bar{Y})}{\sqrt{\sum (X - \bar{X})^2 \sum (Y - \bar{Y})^2}}$$

4.4 Признаки от гироскопа

Для гироскопа были выбраны следующие признаки (большинство использовалось в работе [17])

1. Средние значения для каждой из осей: $\bar{x}, \bar{y}, \bar{z}$
2. Стандартные отклонения для каждой из осей: s_x^2, s_y^2, s_z^2
3. Корреляция между показаниями различных осей: r_{XY}, r_{XZ}, r_{YZ}
4. Signal Magnitude Area = $\frac{1}{T} \sum_{i=1}^T |x_i| + |y_i| + |z_i|$
5. Мощность сигнала по каждой из осей: $P_v = \frac{1}{T} \sum_{i=1}^T v_i^2$
6. Magnitude Mean Value = $\sqrt{\bar{x}^2 + \bar{y}^2 + \bar{z}^2}$

5 Отбор признаков

5.1 Random Forest

Главный недостаток алгоритма Random Forest [18] состоит в отсутствии возможности визуального представления процесса принятия решений и сложности интерпретации полученного решения. Однако предложенные Брейманом меры информативности позволяют выделять наиболее информативные признаки [19]. Наиболее используемой сферой применимости случайных лесов (помимо классификации и регрессии) является задача выделения наиболее информативных признаков. Брейманом было предложено 4 меры информативности признаков.

Пусть x_i некоторый признак. Три первые меры информативности основаны на оценке влияния случайной перестановки значений этого признака в ООВ¹ выборках на результаты классификации. Первая мера вычисляется следующим образом:

1. Построить случайный лес и получить оценку вероятности ошибочной классификации e для каждого дерева методом ООВ;
2. В ООВ выборках для каждого дерева из построенного случайного леса произвести случайную перестановку значений признака x_i ;
3. Получить оценку вероятности ошибочной классификации \hat{e}_i для каждого дерева по модифицированным ООВ выборкам;
4. Определить информативность признака x_i как максимальное возрастание вероятности ошибки по всем деревьям: $I_1(x_i) = \max_i(0, \hat{e}_i - e_i)$.

Вторая и третья меры используют понятие отступа (margin). Пусть $(\mathbf{x}; y)$ – элемент обучающей выборки. Отступ $marg(\mathbf{x}; y)$ определяется как разность между долей деревьев в лесу, правильно классифицирующих $(\mathbf{x}; y)$ и максимумом из долей деревьев, относящих $(\mathbf{x}; y)$ в другие классы. В результате перестановки значений

¹метод Out-Of-Bag (ООВ), предложенный Брейманом [20], обеспечивает получение естественной оценки вероятности ошибочной классификации случайных лесов на основе наблюдений, не входящих в обучающие бутстреп-выборки, используемые для построения деревьев (эти наблюдения называются ООВ выборками)

признака x_i отступ уменьшается. В качестве меры информативности берется среднее значение (по всем наблюдениям) уменьшения отступа, т. е.

$$I_2(x_i) = \frac{1}{l} \sum_{j=1}^l (\text{marg}(\mathbf{x}_j, y_j) - \text{marg}_i(\mathbf{x}_j, y_j)),$$

где $\text{marg}_i(\mathbf{x}; y)$ означает отступ, вычисленный по ООВ выборке со случайной перестановкой значений признака x_i .

Мера 3 равна разности между количеством отступов, которые уменьшились, и количеством отступов, которые увеличились в результате перестановки значений признака x_i :

$$I_3(x_i) = [\text{marg}(\mathbf{x}; y) > \text{marg}_i(\mathbf{x}; y)] - [\text{marg}(\mathbf{x}; y) < \text{marg}_i(\mathbf{x}; y)]$$

Мера 4 определяется как среднее уменьшение загрязненности вершин, обусловленное данным признаком, а именно

$$I_4(x_i) = \frac{1}{k} \sum_t \Delta i(t) I(i, t),$$

где суммирование осуществляется по всем вершинам деревьев случайного леса, $\Delta i(t)$ - уменьшение загрязненности в вершине t , и $I(i; t)$ - индикаторная функция, равная 1, если признак x_i был выбран для расщепления в вершине t .

В пакете Random Forest языка R [21] для отбора признаков используется модифицированный вариант меры 1. Отличие состоит в том, что берется не максимум возрастания вероятности ошибки, а усреднение этой ошибки:

$$I(x_i) = \frac{1}{T} \sum_{i=1}^T \max(0, \hat{e}_i - e_i)$$

5.2 LDA

Linear Discriminate Analysis является простым, но очень эффективным алгоритмом классификации [22]. Кратко напомним его суть. Если есть K различных меток классов, то LDA предполагает, что плотность распределения объектов каждого класса может быть представлена многомерной нормальной плотностью:

$$f(x|k) = (2\pi)^{-p/2} |\Sigma|^{-1/2} \exp\left\{ -\frac{1}{2} (\mathbf{x} - \mu_k)^T \Sigma^{-1} (\mathbf{x} - \mu_k) \right\}$$

со средним μ_k и общей ковариационной матрицей Σ .

Алгоритм предполагает модель смеси распределений для данных:

$$f(x) = \sum_{j=1}^K \pi_j f(x|j).$$

Вероятность того, что данный объект x принадлежит классу k вычисляется с помощью теоремы Байеса:

$$Pr(k|x) = \frac{\pi_k f(x|k)}{f(x)}.$$

Оценка дискриминанта LDA определяется как логарифм апостериорной вероятности $d_k(x) = \log\{Pr(k|x)\}$, который после группировки всех членов принимает следующий вид:

$$d_k^{LDA}(x) = \mu_k^T \Sigma^{-1} x - \frac{1}{2} \mu_k^T \Sigma^{-1} \mu_k + \log(\pi_k).$$

Эта оценка линейна по x , что и отражено в названии алгоритма. Классификация в данном методе проходит следующим образом: оценивается функция дискриминанта для всех классов k и выбирается тот класс, который максимизирует апостериорную вероятность.

Для того, чтобы оценить важность каждого признака перепишем приведенную выше стандартную форму метода LDA. Для этого добавим независящие от классов константу в функцию дискриминанта. Вычислим объединенное среднее:

$$\mu_{pool} = \sum_{j=1}^K \frac{n_j}{n} \mu_j,$$

которое представляет собой центр масс выборки (n_j – количество объектов с классом j в выборке, $n = \sum_{j=1}^K n_j$ – общее количество наблюдений). Соответствующая оценка дискриминанта:

$$d_{pool}^{LDA} = \mu_{pool}^T \Sigma^{-1} x - \frac{1}{2} \mu_{pool}^T \Sigma^{-1} \mu_{pool}.$$

Теперь можно вычислить полностью эквивалентную в плане предсказаний оценке d_k^{LDA} новую оценку:

$$\Delta_k^{LDA} = d_k^{LDA}(x) - d_{pool}^{LDA}(x),$$

которая после преобразований переходит в

$$\Delta_k^{LDA} = \omega_k^T \delta_k(x) + \log(\pi_k)$$

с вектором весов признаков $\omega_k = P^{-1/2}V^{-1/2}(\mu_k - \mu_{pool})$ и предиктора Махаланобиса $\delta_k(x) = P^{-1/2}V^{-1/2}\left(x - \frac{\mu_k + \mu_{pool}}{2}\right)$.

Здесь было произведено разложение ковариационной матрицы $\Sigma = V^{1/2}P^{1/2}$, где $V = \text{diag}\{\sigma_1^2, \dots, \sigma_p^2\}$ диагональная матрица с дисперсиями и $P = (\rho_{ij})$ матрица корреляций.

Для отбора признаков используются предложенные в [23] cat scores:

$$\tau_k^{adj} \equiv \left(\frac{1}{n_k} + \frac{1}{n}\right)^{-1/2} \omega_k = P^{-1/2} \times \left\{ \left(\frac{1}{n_k} + \frac{1}{n}\right) V \right\}^{-1/2} (\mu_k - \mu_{pool}) = P^{-1/2} \tau_k$$

Итоговая оценка для важности признака $i \in \{1, \dots, p\}$ равна:

$$S_i = \sum_{j=1}^K (\tau_{i,j}^{adj})^2,$$

таким образом, суммируются i -ые компоненты векторов $\tau_{\mathbf{k}}^{\text{adj}} = (\tau_{1,k}^{adj}, \dots, \tau_{p,k}^{adj})^T$ по всем K группам.

6 Вычислительные эксперименты

6.1 Условия экспериментов

При решении задачи важно, чтобы построенный алгоритм был независим от конкретного пользователя. Таким образом, не нужно каждый раз проводить предварительную настройку на пользователя, а можно сразу проводить классификацию на новых данных. Поэтому все эксперименты осуществлялись по методике leave-one-out: контроль – это все данные одного человека, обучение – данные от всех других людей.

Для работы с сигналами была выбрана техника 50% пересекающих окон [24]. Два соседних окна имеют пересечение в 256 измерений. Для обучения выбирается окно небольшого размера (для каждого сигнала рассматриваются окна по 512 отсчетов). Для этого окна мы знаем верный класс и можем извлечь признаки. Таким образом формируется обучающая выборка. В контроле считаем, что нужно определить

месторасположение телефона по 5 окнам, которые пересекаются на 50%, т.е информации за 1536 измерений. Вариант итоговой классификации – это вопрос, который тоже требует экспериментов. Поэтому будут протестированы следующие варианты:

- Выбор самого часто предсказываемого класса: $\operatorname{argmax}_i \sum_{w=1}^5 [p_w = i]$, где

$$[z] = \begin{cases} 1, & \text{если выражение } z \text{ истинно} \\ 0, & \text{иначе.} \end{cases}$$

- Выбор класса, который в сумме получил наибольшую вероятность по всем окнам: $\operatorname{argmax}_i \sum_{w=1}^5 p_w^i$, где p_w^i – вероятность того, что наблюдаемое окно w имеет класс i .
- Двухступенчатый классификатор, который изображен на Рис. 13. Он на первом шаге определяет, что окно относится к одному из 2 классов и на втором выдает окончательную классификацию.




Рис. 13: Двухступенчатый классификатор

6.2 Методы оценки качества решения

В области машинного обучения широко используется матрица неточностей (confusion matrix) [25], которая позволяет визуализировать результаты работы алгоритма. Эта матрица размера N на N , где N – это количество классов. Строки этой матрицы соответствуют истинным классам, а столбцы решениям классификатора. При классификации объекта из тестовой выборки мы увеличиваем число стоящее на

пересечении столбца класса, который вернул классификатор и строки класса к которому действительно относится данный объект. Название связано с тем, что такая матрица позволяет легко увидеть те классы, которые путает алгоритм.

Имея такую матрицу точность и полнота для каждого класса рассчитывается очень просто. Точность равняется отношению соответствующего диагонального элемента матрицы и суммы всего столбца класса. Полнота – отношению диагонального элемента матрицы и суммы всей строки класса:

$$Precision_c = \frac{A_{c,c}}{\sum_{i=1}^n A_{c,i}},$$

$$Recall_c = \frac{A_{c,c}}{\sum_{i=1}^n A_{i,c}}$$

Результирующая точность классификатора рассчитывается как арифметическое среднее его точности по всем классам. Аналогично вычисляется результирующая полнота.

В данной работе каждое значение confusion matrix делилось на сумму строки, чтобы сразу было понятно качество работы алгоритма.

6.3 Распознавание по данным от акселерометра

Для удаления неинформативных участков сигнал по каждой из осей x, y, z разбивался на окна. Считалась дисперсия сигнала D_x, D_y, D_z . Для каждого окна w_{ij} , где $i \in \{x, y, z\}$, j – это порядковый номер окна, считалась характеристика

$$\lambda_i = \begin{cases} 0, & \text{если дисперсия окна } w_{ij} \text{ в } \alpha \text{ раз меньше, чем } D_i, \\ 1, & \text{иначе.} \end{cases}$$

Оставлялись только те окна, где $\lambda_x \lambda_y \lambda_z = 1$. Данный алгоритм позволяет убирать участки на которых колебания сигнала очень малы. Для подбора значения α вручную для нескольких человек были размечены участки на 2 класса: информативные и неинформативные. Экспериментальным путем было получено значение $\alpha = 10$.

Для очистки сигнала от шума был выбран фильтр нижних частот с критической частотой равной $w = 0.1$. На Рис. 14 показан пример применения этого фильтра на реальных данных. Синим цветом отмечены оригинальные значения. Красной линией соединены значения после фильтрации.




Рис. 14: Применение фильтра нижних частот

Для решения задачи рассмотрим простую модель:

- Рассматриваются только признаки от осей x, y, z и от общего ускорения $\text{magnitude} = \sqrt{x^2 + y^2 + z^2}$.
- Используется только первая группа признаков для акселерометра.

Запустим алгоритм Random Forest с небольшим количеством деревьев (=20), чтобы получить какие-то базовые представления о возможности решения задачи.

Таблица 5: Результаты работы алгоритма RF при использовании только первой группы признаков

true/recognition	backpack	bag	hand	pocket
backpack	0.4136	0.0471	0.1885	0.3508
bag	0.2645	0.0413	0.5537	0.1405
hand	0.0374	0.0238	0.9253	0.0136
pocket	0.0865	0.0063	0.0612	0.8460

Видим, что классы hand и rocket распознаются с достаточно хорошей точностью. Другие же 2 класса распознаются плохо: bag путается с rocket, а backpack с hand. Теперь оставим для каждой оси по одному лучшему признаку:

- Квантиль уровня 0.25 для оси x.
- Среднее значение сигнала для оси y.
- Квантиль уровня 0.1 для оси z.
- Квантиль уровня 0.25 для общего ускорения.



Рис. 15: Распределение объектов в пространствах пар признаков

Таблица 6: Результаты работы алгоритма RF при использовании 4 признаков

true/recognition	backpack	bag	hand	pocket
backpack	0.356	0.042	0.220	0.382
bag	0.686	0.000	0.107	0.207
hand	0.048	0.025	0.903	0.024
pocket	0.095	0.017	0.068	0.821

При аналогичных условиях запустим алгоритм Linear Discriminant Analysis (LDA)

Таблица 7: Результаты работы алгоритма LDA при использовании только первой группы признаков

true/recognition	backpack	bag	hand	pocket
backpack	0.288	0.099	0.199	0.414
bag	0.512	0.165	0.124	0.198
hand	0.037	0.037	0.878	0.048
pocket	0.017	0.019	0.065	0.899

Рассмотрим вторую модель, которая отличается от первой добавлением всех групп признаков.

Таблица 8: Результаты работы алгоритма RF при использовании всех групп признаков

true/recognition	backpack	bag	hand	pocket
backpack	0.4398	0.262	0.1728	0.3613
bag	0.2645	0.0496	0.5372	0.1488
hand	0.0611	0.0255	0.8761	0.0374
pocket	0.0612	0.0042	0.0591	0.8755

Заметим, что класс bag очень плохо отделяется нашими алгоритмами от других. Попробуем объединить классы bag и backpack в один класс bag.

Таблица 9: Результаты работы алгоритма RF на 3 классах

true/recognition	bag	hand	pocket
bag	0.612	0.202	0.186
hand	0.102	0.871	0.027
pocket	0.093	0.049	0.859

Оставим 8 самых важных признаков, которые были выбраны алгоритмами отбора как самые лучшие:

- $\text{quantile}_{0.1}Z$ – квантиль порядка 0.1 для оси Z,
- $\text{mean}Y$ – среднее значение для оси Y,
- mobility_{AH} – mobility для горизонтальной проекции,
- dwa – Durbin-Watson autocorrelation,
- $\text{quantile}_{0.25}X$ – квантиль порядка 0.25 для оси X,
- complexity_{AV} – complexity для вертикальной проекции,

- $\text{quantile0.1diff0.05Jerk}$ – разность квантилей порядка 0.1 и 0.05 для Jerk-фильтра,
- corrMagAv – корреляция между значениями общего ускорения и вертикальной проекции.



Рис. 16: Распределение объектов в пространствах 8 лучших признаков

Таблица 10: Результаты работы алгоритма RF на 3 классах при использовании 8 признаков

true/recognition	bag	hand	pocket
bag	0.647	0.160	0.192
hand	0.076	0.903	0.020
pocket	0.105	0.044	0.850

Таблица 11: Результаты работы алгоритма LDA на 3 классах при использовании 8 признаков

true/recognition	bag	hand	pocket
bag	0.362	0.205	0.433
hand	0.032	0.927	0.041
pocket	0.158	0.076	0.766

Попробуем использовать другие схемы классификации.

Таблица 12: Результаты работы алгоритма RF на 3 классах при использовании схемы с суммой вероятностей

true/recognition	bag	hand	pocket
bag	0.641	0.157	0.202
hand	0.059	0.920	0.020
pocket	0.099	0.049	0.852

Рассмотрим работу алгоритма с использованием 8 описанных выше признаков на каждом наборе данных в отдельности.

Таблица 13: Результаты работы алгоритма RF на первом наборе данных

true/recognition	bag	hand	pocket
bag	0.690	0.160	0.150
hand	0.077	0.883	0.040
pocket	0.148	0.124	0.729

Таблица 14: Результаты работы алгоритма RF на втором наборе данных

true/recognition	bag	hand	pocket
bag	0.7440	0.0640	0.1920
hand	0.0035	0.9931	0.0035
pocket	0.0227	0.0038	0.9735

Как видно на втором наборе данных результаты заметно выше.

6.4 Распознавание по данным от акселерометра и гироскопа

Данные эксперименты будут проводиться на наборе данных Walk Detection and Step Counting on Unconstrained Smartphones[4].

Таблица 15: Результаты работы алгоритма RF при использовании только данных гироскопа

true/recognition	backpack	bag	hand	pocket
backpack	0.4894	0.0851	0.0106	0.4149
bag	0.3871	0.0000	0.4194	0.1935
hand	0.0138	0.0000	0.9827	0.0035
pocket	0.0038	0.0000	0.0076	0.9886

Результаты получаемых при использовании классификации по данным гироскопа сравнимы с результатами, получаемыми при использовании только данных акселерометра. В этом случае опять нельзя отделить класс bag от других классов.

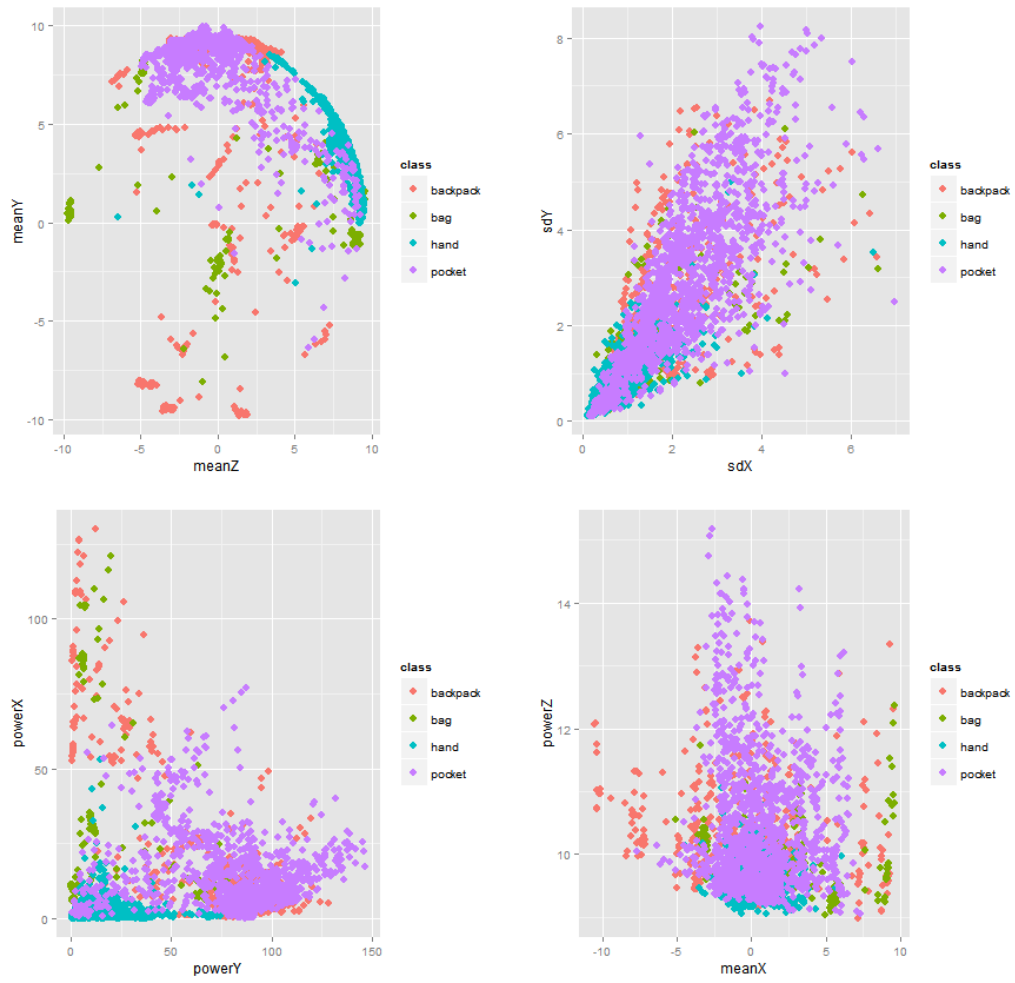


Рис. 17: Распределение объектов в пространствах пар признаков гироскопа

Таблица 16: Результаты работы алгоритма RF на данных гироскопа

true/recognition	bag	hand	pocket
bag	0.5680	0.0960	0.3360
hand	0.0173	0.9792	0.0035
pocket	0.0114	0.0076	0.9811

Теперь попробуем использовать данные акселерометра и гироскопа вместе.

Таблица 17: Результаты работы алгоритма RF на данных акселерометра и гироскопа

true/recognition	bag	hand	pocket
bag	0.7960	0.1040	0.1000
hand	0.0311	0.9654	0.0035
pocket	0.0189	0.0038	0.9773

Попробуем поднять качество при классификации на 4 класса. Для этого построим двухступенчатый классификатор, который изображен на Рис. 13.

Таблица 18: Результаты работы алгоритма RF на первом уровне двухступенчатого классификатора

true/recognition	class1	class2
class1	0.680	0.320
class2	0.014	0.986

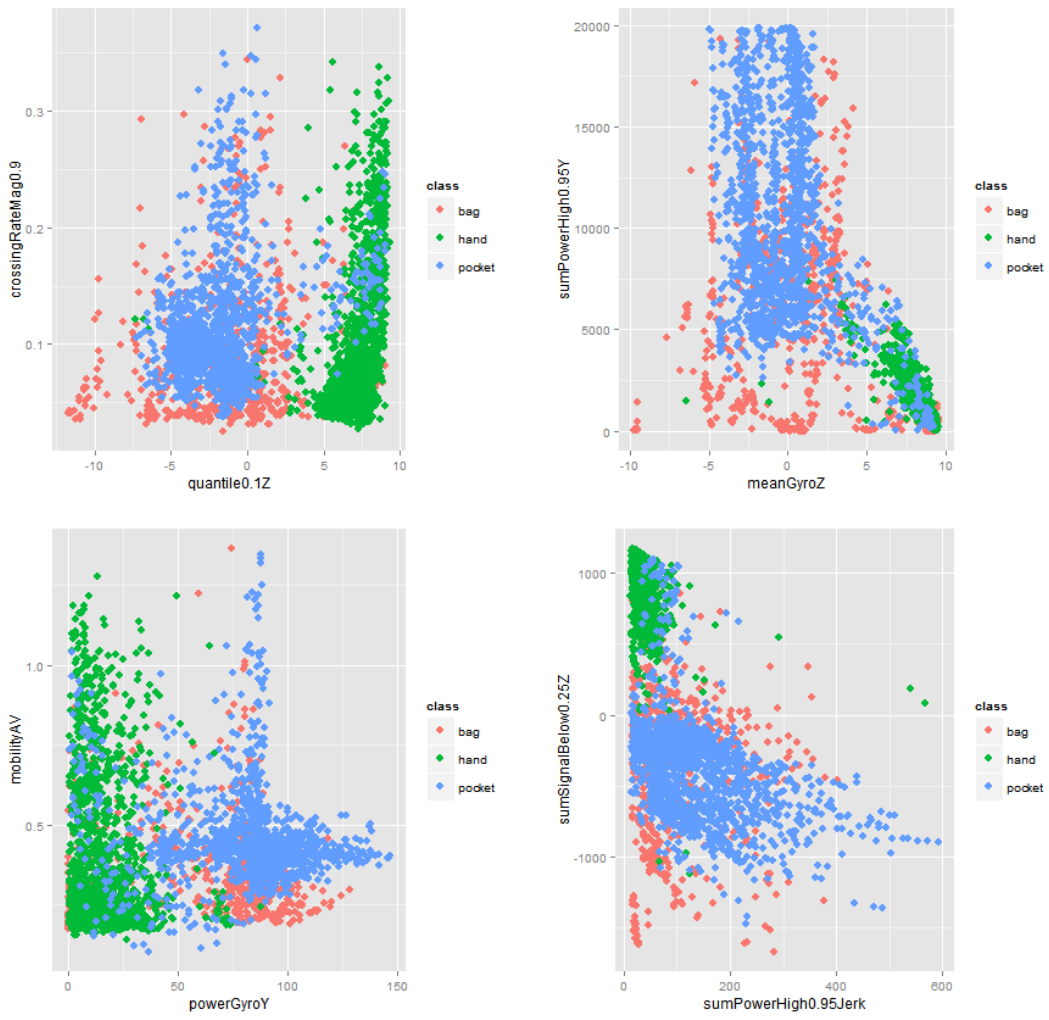


Рис. 18: Распределение объектов в пространствах лучших пар признаков от акселерометра и гироскопа

Таблица 19: Результаты работы алгоритма на втором уровне двухступенчатого классификатора

true/recognition	backpack	bag	hand	pocket
backpack	0.7234	0.0638	0.0106	0.2021
bag	0.5484	0.0000	0.4516	0.0000
hand	0.069	0.0000	0.9654	0.0277
pocket	0.0189	0.0000	0.0076	0.9735

Качество классификации объектов класса bag повысить таким образом не удалось.

Итоговый классификатор состоит из 18 признаков:

- Нормированное на длину окна количество пересечений квантиля уровня 0.25 для общего ускорения.
- Нормированное на длину окна количество пересечений квантиля уровня 0.5 для общего ускорения.
- Нормированное на длину окна количество пересечений квантиля уровня 0.5 для вертикальной проекции.
- Mobility для вертикальной проекции.
- Complexity для вертикальной проекции.
- Среднее значение мощности первой производной для горизонтальной проекции.
- Сумма значений сигнала, лежащих выше квантиля уровня 0.9 для оси Y.
- Мощность сигнала, лежащего выше квантиля уровня 0.9 для оси Y.
- Квантиль уровня 0.1 для оси Z.
- Сумма значений сигнала, лежащих ниже квантиля уровня 0.25 для оси Z.
- Сумма значений сигнала, лежащих выше квантиля уровня 0.95 для jерк-фильтра.

- Сумма значений сигнала, лежащих ниже квантиля уровня 0.1 для jerk-фильтра.
- Среднее значение показаний гироскопа для оси Y.
- Среднее значение показаний гироскопа для оси Z.
- Мощность сигнала гироскопа для оси X.
- Мощность сигнала гироскопа для оси Y.
- Durbin-Watson autocorrelation.
- Magnitude Mean Value.

Рассмотрим устойчивость решения. Для каждого значения количества деревьев будем производить 10 запусков и вычислять среднее качество классификации и стандартное отклонение.




Рис. 19: Качество решение в зависимости от числа деревьев

Видим, что при количестве деревьев ≥ 30 качество классификации превышает 90%.

7 Выводы

В первой части экспериментов были рассмотрены алгоритмы, работающие только на данных акселерометра. Показано, что с помощью небольшого количества признаков можно добиться более чем 87% полноты распознавания классов hand и rocket. На оставшихся двух классах bag и backpack качество намного ниже. Класс bag определять верно хоть с каким-то приемлемым качеством не удастся, поэтому было принято решение объединить классы bag и backpack в один. Активность пользователя влияет на качество классификации – при схожей активности всех пользователей качество выше, чем при наличии разного вида действий у пользователей.

Во второй части была добавлена информация от гироскопа. Использование только данных гироскопа позволяет более чем с 98% полнотой определять классы bag и backpack. На классах bag и backpack качество получается низким. Даже объединение этих классов в один класс не позволяет добиться приемлемого качества.

При совместном использовании данных гироскопа и акселерометра удалось построить алгоритм, результирующая полнота которого превышает 90%. При этом показано, что для такого алгоритма оптимальное количество деревьев является небольшим (~30).

8 Заключение

В настоящей дипломной работе:

- Исследованы методы обработки сигналов сенсорных устройств и их применение для решения задачи определения месторасположения телефона.
- Программно реализованы все необходимые алгоритмы и модуль для проведения экспериментов.
- Проведены вычислительные эксперименты на двух реальных наборах данных. Итоговый алгоритм показал приемлемый результат работы.

Работа была представлена на XXI международную научную конференцию «Ломоносов - 2014» [26]. Работа поддержана грантом РФФИ, номер проекта 14-07-00965.

Список литературы

- [1] Seyed Amir Hoseinitabatabaei, Alexander Gluhak, Rahim Tafazolli: A Survey on Smartphone-Based Systems for Opportunistic User Context Recognition // ACM Computing Surveys, Vol. 45, No. 3, Article 27, 2013
- [2] Ozlem Durmaz Incel, Mustafa Kose, Cem Ersoyg: A Review and Taxonomy of Activity Recognition on Mobile Phones // BioNanoSci. (2013) 3:145–171 DOI 10.1007/s12668-013-0088-3
- [3] Pekka Siirtola, Juha Roning: Recognizing Human Activities User-independently on Smartphones Based on Accelerometer Data // IJIMAI 1(5): 38-45, 2012
- [4] <http://www.cl.cam.ac.uk/ab818/ubicomp2013.html>
- [5] Agata Brajdic, Robert Harle: Walk Detection and Step Counting on Unconstrained Smartphones // UbiComp, page 225-234. ACM, 2013
- [6] J. Yang: Toward Physical Activity Diary: Motion Recognition Using Simple Acceleration Features with Mobile Phones // Proc. 1st Int. Workshop on IMCE at ACM Multimedia 2009, ACM Press, 2009, pp. 1-10
- [7] Adil Mehmood Khan, Muhammad Hameed Siddiqi, Seok-Won Lee: Exploratory Data Analysis of Acceleration Signals to Select Light-Weight and Accurate Features for Real-Time Activity Recognition on Smartphones // Sensors, 13, 13099-13122, 2013
- [8] Jon Edwin Cobb: An accelerometer based gestural capture system for performer based music composition, 2011
- [9] Radoslav Stoichkov: Android Smartphone Application for Driving Style Recognition, 2013
- [10] Rudolph Emil Kalman: A New Approach to Linear Filtering and Prediction Problems // Transactions of the ASME–Journal of Basic Engineering, 82, Series D, 35-45, 1960
- [11] Mridul Khan, Sheikh Iqbal Ahamed, Miftahur Rahman, Roger O. Smith: A Feature Extraction Method for Realtime Human Activity Recognition on Cell Phones, 2011

- [12] Pedro Batista, Carlos Silvestre, Paulo Oliveira, Bruno Cardeira: Accelerometer Calibration and Dynamic Bias and Gravity Estimation: Analysis, Design, and Experimental Evaluation, 2009
- [13] Wilhelmiina Hamalainen, Mikko Jarvinen, Paula Martiskainen, Jaakko Mononen: Jerk-based feature extraction for robust activity recognition from acceleration data, 11th International Conference on Intelligent Systems Design and Applications, 831-836, 2011
- [14] Bo Hjorth: EEG analysis based contributions on time domain properties, *Electroenceph. clin. Neurophysiol.*, 29:306-310, 1970
- [15] J. Durbin, G. S. Watson: Testing for Serial Correlation in Least Squares Regression, I, *Biometrika* 37 (3-4): 409-428, 1950
- [16] Yunus Emre Ustev, Cem Ersoy, Ozlem Durmaz Incel : User, Device and Orientation Independent Human Activity Recognition on Mobile Phones: Challenges and a Proposal, UbiComp'13, September 8-12, 2013,
- [17] Jafet Morales: Human activity recognition from accelerometer and gyroscope data, 2013
- [18] T. Hastie, R. Tibshirani, J. Friedman: Chapter 15. Random Forests // *The Elements of Statistical Learning: Data Mining, Inference, and Prediction.* — 2nd ed. — Springer-Verlag, 2009
- [19] L. Breiman: Random Forests. *Machine Learning* 45 (1): 5–32, 2001
- [20] L. Breiman: Out-of-bag estimation, Technical report, Statistics Department, University of California Berkeley, Berkeley CA 94708, 1996b.
- [21] <http://cran.r-project.org/web/packages/randomForest/randomForest.pdf>
- [22] G. J. McLachlan: *Discriminant Analysis and Statistical Pattern Recognition.* Wiley Interscience, 2004
- [23] V. Zuber and K. Strimmer: Gene ranking and biomarker discovery under correlation // *Bioinformatics* 25 (20): 2700-2707, 2009

- [24] Nishkam Ravi, Nikhil Dandekar, Preetham Mysore, Michael L. Littman: Activity Recognition from Accelerometer Data, 2005
- [25] Stephen V. Stehman: Selecting and interpreting measures of thematic classification accuracy // Remote Sensing of Environment 62 (1): 77–89, 1997
- [26] Остапец А.А. Анализ сигналов сенсорных устройств // Сборник тезисов XXI международной научной конференции Ломоносов - 2014. Издательский отдел факультета вычислительной математики и кибернетики МГУ имени М.В. Ломоносова, 2014. С. 41-43.