

УДК: 004.94

# ИДЕНТИФИКАЦИЯ ПРИЛОЖЕНИЙ В СИСТЕМАХ МИЛЛИМЕТРОВОГО/ТЕРАГЕРЦЕВОГО ДИАПАЗОНА ЧАСТОТ С ПОМОЩЬЮ АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ

**В.О. Бегишев**

*Российский университет дружбы народов имени Патриса Лумумбы*  
Россия, 117198, Москва, Миклухо-Маклая ул., 6  
E-mail: begishev-vo@rudn.ru

**С.А. Дугаева**

*Российский университет дружбы народов имени Патриса Лумумбы*  
Россия, 117198, Москва, Миклухо-Маклая ул., 6  
E-mail: dugaeva-sa@rudn.ru

**Ключевые слова:** 5G/6G, системы сотовой связи, микроподвижность, обнаружение приложений, машинное обучение.

**Аннотация:** Отслеживание луча является критически важной функцией в современных системах нового радио (NR) миллиметрового диапазона (mmWave) и, как ожидается, станет еще более важной в будущих системах 6G, работающих в терагерцевом (ТГц) диапазоне частот. Для обеспечения бесперебойной связи базовым станциям (БС) необходимо периодически вызывать эту процедуру. Из-за использования массивных антенных решеток в системах 6G ТГц объем ресурсов, потребляемых отслеживанием луча, будет чрезвычайно большим, что делает временной интервал между конфигурациями качающегося луча очень важным параметром. Одним из явлений, влияющих на выбор этого интервала, является микроподвижность пользовательского оборудования (ПУ) – быстрые перемещения и вращения ПУ в руках пользователя происходят даже тогда, когда последний находится в неподвижном положении. В этой статье, используя алгоритмы машинного обучения (ML), мы предлагаем процедуру обнаружения центра луча на стороне БС для приложений, характеризующихся различными типами микроподвижности. Мы демонстрируем, что можно безопасно различать приложения, характеризующиеся как низкими, так и совершенно разными скоростями микроподвижности. Все рассмотренные классификаторы, включая дерево, случайный лес и нейронную сеть, работают качественно одинаково. Для приложений с высокими и схожими скоростями микроподвижности, таких как виртуальная реальность и игры, точность классификации остается на уровне около 85-90%. Однако эта потеря точности не влияет на конечную цель алгоритма обнаружения удаленных приложений – понимание того, как часто процедура выравнивания луча должна вызываться на UE и BS.

## 1. Введение

Увеличение пропускной способности интерфейса доступа сотовых систем следующего поколения (5G и 6G) обусловлено необходимостью работы в миллиметровом и терагерцевом диапазонах частот [1, 2]. Для обеспечения

направленной передачи и приема сигналов базовые станции используют массивные антенные решетки, что требует периодического отслеживания луча для поддержания связи.

В исследовании рассматриваются два важных явления, влияющих на непрерывность соединения: блокировку и микромобильность. Для эффективного преодоления этих проблем предлагается метод удаленного обнаружения типа приложения на пользовательском оборудовании с использованием алгоритмов машинного обучения. Этот подход позволяет адаптировать интервал отслеживания луча на базовых станциях в зависимости от типа приложения, что в свою очередь оптимизирует использование ресурсов [3-5].


Численные результаты подтверждают высокую точность различения типов приложений с разными скоростями микромобильности. Это открывает перспективы для улучшения эффективности сотовых систем нового поколения, где использование терагерцового диапазона частот представляет вызовы и требует инновационных методов для обеспечения стабильного и высококачественного соединения между базовыми станциями и пользовательским оборудованием [6].

## 2. Измерения, свойства и моделирование микромобильности

### 2.1. Настройка измерений

Мы рассматриваем двухточечную связь между базовой станцией (БС) и пользовательское устройство (ПУ), как показано на рис. 1. Предполагается, что и ПУ, и БС работают с использованием решеток, создающих диаграммы направленности антенн. В предложенной ТГц системе БС кажется прочно зафиксированной, в то время как пользователь, связанный с ПУ, находится в стационарном положении. Однако даже в стационарных условиях ожидается, что ПУ в руках пользователя будет выполнять небольшие перемещения и вращения, которые модулируются воспринимаемым контентом. В частности, это небольшие перемещения по осям  $Ox$  и  $Oy$  повороты по вертикальной и поперечной осям. Эти типы перемещений могут вызвать потерю соединения между ПУ и БС. Обратите внимание, что микроизменения по оси  $Oz$ , а также повороты по продольной оси не влияют на состояние соединения.

Для оценки микромобильности ПУ использовалась лазерная указка, прикрепленная к смартфону. Эксперименты проводились на расстоянии 2 м от ПУ до экрана с использованием видеокамеры разрешением  $1280 \times 720$  и частотой 30 кадров в секунду. Рассматривались четыре приложения: просмотр видео, телефонные звонки, VR-просмотр и гоночные игры. Для каждого сценария проведено по 10 независимых экспериментов с продолжительностью 10 секунд. Полученные данные включают около 3300 точек на каждое приложение.



**Рис. 1.** Рассматриваемый сценарий терагерцового взаимодействия между пользовательским устройством и базовой станцией.

### 3. Предлагаемый подход

#### 3.1. Общие описание предлагаемого подхода

Суть предложенной идеи заключается в удаленном определении типов приложений с разной скоростью микромобильности, что позволяет оптимизировать частоту выравнивания луча между базовой станцией и пользовательским оборудованием. Предлагается постоянное контролирование уровня принимаемого сигнала базовой станцией, использование данных о траектории центра луча и алгоритмов машинного обучения для классификации приложений. Эксперименты с использованием моделей марковских движений и машинного обучения проведены для оценки предложенного подхода.

#### 3.2. Описание используемых алгоритмов

В нашем исследовании мы рассматриваем три типа алгоритмов ML для удаленного обнаружения приложений. Это деревья решений, случайные леса и нейронные сети. Ниже мы приводим их краткое описание и обсуждаем параметризацию.

**Древо решений.** Алгоритм дерева решений работает путем рекурсивного разделения набора данных на подмножества на основе значений признаков с целью максимизировать прирост информации при каждом разделении. Прирост информации является мерой уменьшения энтропии или беспорядка в наборе данных и рассчитывается как

$$I(D, F) = H(D) - H(D|F),$$

где  $I(D, F)$  – прирост информации,  $D$  – набор данных,  $F$  – рассматриваемый признак,  $H(D)$  – энтропия набора данных,  $H(D|F)$  – условная энтропия набора данных с учетом признака  $F$ .

Энтропия набора данных рассчитывается как

$$H(D) = - \sum (p_i \log_2(p_i)),$$

где  $p_i$  – доля экземпляров в наборе данных, принадлежащих классу  $i$ .

Алгоритм дерева решений разделяет набор данных на основе объектов с наибольшим приростом информации до тех пор, пока не будет выполнен критерий остановки, например максимальная глубина дерева или минимальное количество экземпляров в каждом листовом узле.

**Случайный лес.** Случайный лес – это алгоритм ансамблевого обучения, который строит множество деревьев решений во время обучения и определяет классификацию или регрессию на основе режима классов (в случае классификации) или среднего предсказания (в случае регрессии) отдельных деревьев. Каждое дерево строится на случайном подмножестве обучающих данных, создавая уникальное "подпространство признаков". Алгоритм выбирает случайные признаки для построения каждого дерева, разделяет данные на основе их значений и использует голосование для окончательного прогноза. В случайных лесах прогнозируемые выходные данные каждого дерева решений агрегируются для определения окончательного прогноза. Пусть  $Y$  обозначает метку класса входного примера и пусть  $T$  это количество деревьев решений в случайном лесу. Затем выходные данные случайного леса, обозначенные как  $\hat{Y}$ , вычисляются как

$$\hat{Y} = M(Y_1, Y_2, \dots, Y_t),$$

где  $M$  – статистический режим.

**Нейронная сеть.** Нейронная сеть прямого распространения – базовая форма нейронной сети с входным слоем, одним или несколькими скрытыми слоями и выходным слоем. Каждый слой содержит набор нейронов, связанных с нейронами

соседних слоев через веса. Выходной сигнал нейрона определяется взвешенной суммой входных данных, проходящих через функцию активации, такую как сигмовидная или ReLU, добавляя нелинейность для изучения сложных закономерностей в данных. В частности, выходной сигнал нейрона в слое  $j$  можно вычислить как

$$z_j = \sum (w_{i,j} * x_i) + b_j, a_j = g(z_j),$$

где  $w_{i,j}$  – вес связи между нейроном  $i$  в слое  $j - 1$  и нейроном  $j$  в слое  $j$ ,  $x_i$  – входное значение для нейрона  $i$ ,  $b_j$  – член смещения для нейрона  $j$ ,  $g(\cdot)$  – функция активации,  $z_j$  – взвешенная сумма входных данных для нейрона  $j$ ,  $a_j$  – выходное значение нейрон  $j$ .

Выходные данные нейронной сети получаются путем применения процесса прямой связи к входному слою и распространения вычисленных значений через каждый слой до тех пор, пока не будет достигнут выходной слой. Во время обучения веса и смещения нейронной сети корректируются так, чтобы минимизировать разницу между прогнозируемым и фактическим выходными данными с использованием функции потерь. Наиболее часто используемой функцией потерь для задач регрессии является функция среднеквадратической ошибки (MSE), которая измеряет среднеквадратичную разницу между прогнозируемыми и фактическими выходными данными. Веса и смещения обновляются с использованием алгоритма оптимизации, такого как градиентный спуск, который итеративно корректирует веса в направлении наибольшего спуска функции потерь. Этот процесс называется обратным распространением ошибки и позволяет нейронной сети узнать оптимальные веса и смещения, которые минимизируют функцию потерь.

### 3.3. Реализация

Для построения трасс использовались исходные данные в формате начальной точки, точки перехода и вероятности перехода. Траектории ПУ генерировались с использованием процедуры генерации траекторий марковского процесса для 100000 трейсов каждого приложения. Для классификации использовались признаки, такие как среднее расстояние от центра, средняя скорость движения и другие. Модель классификации была построена с использованием Classification Learner в Matlab, включая рассмотрение дерева решений, случайных лесов и нейронных сетей. Применялась функция Feature Selection для определения веса вклада каждого признака в точность классификации, оцененной на всех данных, включая тестовые данные.

## 4. Числовые результаты

### 4.1. Объединенная классификация

Изучив классификацию попарных приложений, перейдем к сообщению результатов классификации всех приложений в целом. На рисунке 4 представлена зависимость точности классификации для всех рассмотренных алгоритмов от доли трейсов, используемых для тестирования. Наблюдается незначительно более высокая точность для нейронной сети, в то время как древовидные классификаторы чувствительны к размеру обучающей выборки. Потеря точности классификации связана преимущественно с высокой скоростью микромобильности в VR и игровых приложениях, как показывает вклад скорости микромобильности в принятие решения на рис. 2. В условиях неоднородной коллекции следов наибольшую роль играет расстояние до центра.

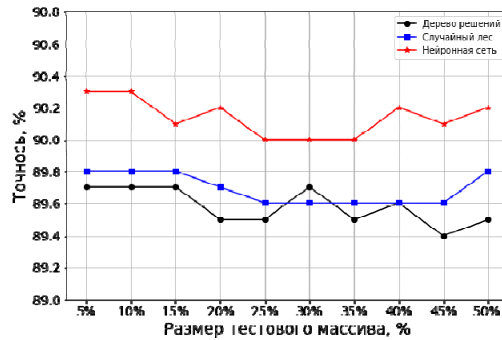


Рис. 2. Точность классификации для всех приложений.

## 5. Заключение

В данной работе мы предложили не интрузивную процедуру удаленного обнаружения типа приложения на пользовательском оборудовании (ПУ), используя траекторию центра луча в системах 5G/6G. Методы машинного обучения (ML) позволяют различать приложения с разной микромобильностью. Предложенный подход оптимизирует временной интервал отслеживания луча, обеспечивая непрерывную связь между ПУ и базовыми станциями с минимальным расходом ресурсов. Результаты показывают эффективность всех классификаторов, особенно в различении низкой скорости микромобильности, хотя точность для высоких скоростей (VR и игры) составляет примерно 85–90%. Несмотря на это, наблюдаемая потеря точности не влияет на основную цель – определение частоты использования процедур выравнивания луча. Важно отметить, что все рассмотренные классификаторы работают схоже, хотя дерево более чувствительно к размеру обучающей выборки.

## Список литературы

1. Zaidi A., Athley F., Medbo J., Gustavsson U., Durisi G., Chen X. 5G Physical Layer: principles, models and technology components. Academic Press, 2018.
2. Matthaiou M., Yurduseven O., Ngo H. Q., Morales-Jimenez D., Cotton S.L., Fusco V.F. The road to 6G: Ten physical layer challenges for communications engineers // IEEE Communications Magazine. 2021. Vol. 59, No. 1. P. 64-69.
3. Petrov V., Pyattaev A., Moltchanov D., Koucheryavy Y. Terahertz band communications: Applications, research challenges, and standardization activities // 2016 8th international congress on ultra modern telecommunications and control systems and workshops (ICUMT). IEEE, 2016. P. 183-190.
4. Balanis C. A. Antenna theory: analysis and design. John Wiley & Sons, 2015.
5. Akyildiz I.F., Jornet J.M. Realizing ultra-massive mimo (1024×1024) communication in the (0.06–10) terahertz band // Nano Communication Networks. 2016. Vol. 8. P. 46-54.
6. Gapeyenko M., Samuylov A., Gerasimenko M., Moltchanov D., Singh S., Aryafar E., Yeh S.P., Himayat N., Andreev S., Koucheryavy Y. Analysis of human-body blockage in urban millimeter-wave cellular communications // 2016 IEEE International Conference on Communications (ICC), IEEE, 2016. P. 1-7.