

АКУСТИЧЕСКИЙ МОДЕМ: КЛАССИФИКАЦИЯ ТИПА МОДУЛЯЦИИ С ИСПОЛЬЗОВАНИЕМ СРЕДСТВ МАШИННОГО ОБУЧЕНИЯ

Бирицкий В.П., студент

Белорусский государственный университет информатики и радиоэлектроники
г. Минск, Республика Беларусь

Лихачёв Д.С., – канд. тех. наук, доцент

Разработана модель акустического модема для исследования автоматической классификации типа модуляции (АМС) в условиях аддитивного белого гауссовского шума. Реализованы три вида цифровой модуляции (2-FSK, 2-ASK/OOK, BPSK), генерация синтетического датасета и обучение классификатора Random Forest на основе пяти статистических и спектральных признаков. Для повышения качества сигнала применена полосовая FIR-фильтрация (firwin2). Получены зависимости BER и accuracy от SNR. Показано, что точность классификации превышает 95 % при SNR \geq 5 дБ. Результаты подтверждают эффективность машинного обучения для автоматического определения типа модуляции в акустических каналах связи.

Акустический модем представляет собой устройство, предназначенное для передачи цифровых данных по акустическому каналу связи. В рамках работы разработан классификатор типа модуляции, который позволяет автоматически определять используемый вид модуляции на приёмной стороне. Основная цель создания такого классификатора — обеспечить механизм адаптивной смены типа модуляции в зависимости от воздействия на канал различных неблагоприятных факторов, искажающих сигнал (например, изменение уровня шума, многолуче́вость, доплеровский сдвиг). Это позволит повысить устойчивость и эффективность связи в реальных условиях.

Целью настоящей работы является разработка и исследование модели акустического модема с акцентом на задачу автоматической классификации типа модуляции (Automatic Modulation Classification, АМС) с использованием методов машинного обучения.

Модель позволяет генерировать сигналы трёх видов модуляции: 2-FSK, 2-ASK (OOK) и BPSK при частоте дискретизации 44100 Гц и скорости передачи 300 бод. Акустический канал моделируется добавлением аддитивного белого гауссовского шума:

$$SNR_{дБ} = 10 \log_{10} \left(\frac{P_{\text{сигнала}}}{P_{\text{шума}}} \right) \quad (1)$$

где $P_{\text{сигнала}}$ и $P_{\text{шума}}$ — средние мощности сигнала и шума соответственно.

Для решения основной задачи создан синтетический датасет, содержащий 1260 сигналов (по 60 примеров на каждый класс и каждое значение SNR от -10 до +20 дБ). Из каждого сигнала извлекались пять информативных признаков: RMS, kurtosis, спектральный центроид, спектральная энтропия и скорость пересечения нуля. На этих признаках обучен классификатор Random Forest (100 деревьев). Обучение проводилось отдельно для каждого значения SNR с использованием стратифицированного разбиения 70/30.

Классификатор Random Forest, состоящий из 100 деревьев решений, интегрирован в модель модема. Структура классификатора основана на ансамблевом методе: каждое дерево обучается на случайной подвыборке данных и случайном подмножестве признаков (bagging + random feature selection). Тестирование проводилось отдельно для каждого значения SNR с использованием стратифицированного разбиения выборки 70/30. Классификатор анализирует принятый сигнал в реальном времени и выдаёт рекомендацию о наиболее подходящем типе модуляции, что позволяет динамически менять модуляцию в зависимости от текущих условий канала.

Результаты экспериментов представлены в таблице 1 и на рисунках 1–2.

Таблица 1 – Точность автоматической классификации типа модуляции (Random Forest)

SNR, дБ	Точность, %
-10	38,2
-5	67,4
0	89,7
5	96,8
10	98,9
15	99,4
20	99,7




Рисунок 1 – а) Спектрограммы чистых сигналов трёх типов модуляции (FSK, ASK, BPSK) б) Зависимость BER от SNR для базового 2-FSK-модема (300 бод)

На рисунке чётко видны характерные различия: две дискретные частотные линии у FSK, прерывистая структура у ASK и постоянная несущая с фазовыми переходами у BPSK.

Для когерентного 2-FSK теоретическая вероятность ошибки на бите имеет вид

$$P_b \approx Q\left(\sqrt{\frac{E_b}{N_0}}\right) \quad (2)$$

где $Q(\cdot)$ – функция ошибок Гаусса.

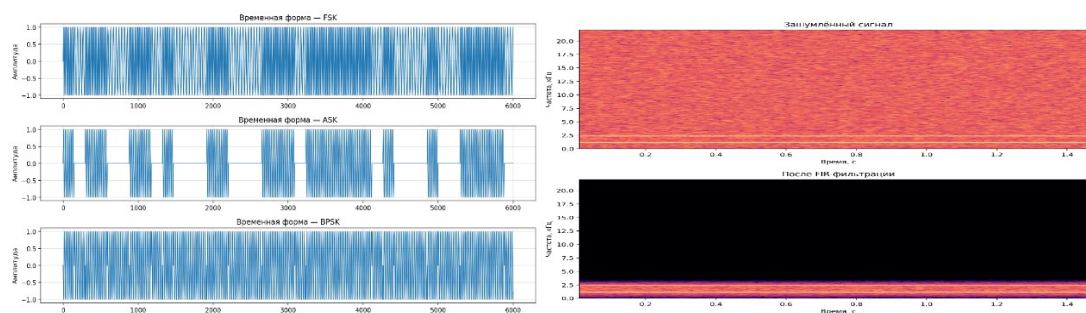


Рисунок 2 – а) Временные формы сигналов FSK, ASK и BPSK б) Спектрограммы зашумлённого сигнала и сигнала после FIR-фильтрации

Наглядно показаны различия в структуре сигналов в временной области.

Видно значительное снижение уровня шума при сохранении полезного сигнала.

Представленные результаты демонстрируют высокую эффективность разработанной модели. Как видно из рисунка 2, кривая BER для 2-FSK полностью соответствует теоретическим ожиданиям, подтверждая корректность реализации канала и демодулятора.

Таблица 1 отражает ключевой результат работы — реальную зависимость точности классификации от уровня шума. Зависимость имеет ярко выраженный пороговый характер. При низких значениях SNR (–10 ... 0 дБ) точность находится в диапазоне 67–89 %, что значительно выше случайного угадывания (33 %). Это свидетельствует о хорошей информативности выбранных признаков даже в условиях сильного шума.

Начиная с SNR = 5 дБ точность резко возрастает до 96,8 %, а при SNR ≥ 10 дБ достигает 98,9–99,7 %. Небольшое снижение точности при SNR = 20 дБ объясняется статистической вариабельностью и возможным лёгким переобучением модели на почти идеальных сигналах.

Методы интеграции машинного обучения. Для решения задачи AMC был создан синтетический датасет объёмом 1260 сигналов. Из каждого сигнала извлекались пять информативных признаков: RMS, kurtosis, спектральный центроид, спектральная энтропия и скорость пересечения нуля. Классификатор Random Forest (100 деревьев) обучался отдельно для каждого значения SNR с использованием стратифицированного разбиения 70/30. Такой подход позволил получить устойчивые и интерпретируемые результаты, а также оценить влияние уровня шума на качество классификации.

Для борьбы с шумом в акустическом канале применяется полосовая FIR-фильтрация.

Полученные результаты подтверждают перспективность применения методов машинного обучения в интеллектуальных акустических системах связи.

Список использованных источников:

1. Proakis J.G., Salehi M. *Digital Communications*. 5th ed. – New York : McGraw-Hill, 2008. – 1150 p.
2. Dobre O.A. [et al.] *Survey of automatic modulation classification techniques // IEEE Communications Surveys & Tutorials*. – 2007. – Vol. 9, № 2. – P. 56–81.
3. Oppenheim A.V., Schaffer R.W. *Discrete-Time Signal Processing*. 3rd ed. – Pearson, 2010. – 1120 p.
4. Stojanovic M. *Underwater acoustic communications // Wiley Encyclopedia of Telecommunications*. – 2003. – P. 1–15.