

А.М. ТАНТУШЯН

**МЕТОДЫ АВТОМАТИЧЕСКОГО РАСПОЗНАВАНИЯ МОДУЛЯЦИЙ
И ИХ СРАВНИТЕЛЬНЫЙ АНАЛИЗ**

Исследованы методы автоматического распознавания модуляций и проведен их сравнительный анализ, позволяющий сделать обоснованный выбор того или иного метода для дальнейшей разработки алгоритма при решении задачи автоматического распознавания модуляций для аналоговых и цифровых модуляций в среде графического программирования LabVIEW.

Ключевые слова: методы автоматического распознавания модуляций, особые ключевые характеристики, машины опорных векторов, искусственные нейронные сети.

Введение. Автоматическое распознавание модуляций (АРМ) является актуальной и важной задачей для систем связи. Исследованием этой задачи и разработкой алгоритмов для ее решения занимаются во многих странах, например, США, Китай, Египет, Индия и др. В настоящее время существует множество классификаторов и алгоритмов, каждый из которых предусмотрен и подходит для решения конкретного вида задач. Целью данной работы является описание некоторых распространенных методов, применяемых для АРМ, и проведение их сравнительного анализа, позволяющего при решении задачи АРМ для аналоговых и цифровых модуляций выбрать наиболее эффективный и целесообразный метод для дальнейшей разработки алгоритма в среде графического программирования LabVIEW. Приведено краткое описание методов теоретического решения, вейвлет-преобразования, машин опорных векторов (МОВ) и искусственных нейронных сетей (ИНС).

1. Метод теоретического решения. Для разработки алгоритмов АРМ существует два основных подхода: метод теоретического решения и метод распознавания образов (МРО). Е.Е. Аззоуз и А.К. Нанди в [1] детально описали разработанные ими алгоритмы для аналоговых и цифровых модуляций как по отдельности, так и в совокупности на основе метода теоретического решения. Эта работа является одним из основных вкладов в развитии АРМ, поскольку подавляющее большинство дальнейших разработок основаны на ней.

Алгоритмы АРМ на основе метода теоретического решения основываются на функции распределения вероятности, которая рассчитывается с помощью параметров принятого сигнала [2]. Классификация происходит

путем сравнения полученных данных с ранее определенными пороговыми значениями. В идеальных условиях классификаторы теоретического решения могут служить эталоном для проверки качества работы других классификаторов. Однако такие классификаторы для оптимизации своей работы требуют дополнительных сложных расчетов. Другим недостатком таких классификаторов является факт, что незнание частоты несущего сигнала, частоты символов, временного сдвига, фазы, мощности сигнала и других параметров значительно ограничивает работу классификатора. Для решения этой проблемы можно рассмотреть неизвестные данные в качестве детерминистических и рассчитать их из принятого сигнала. Такой расчет называется обобщенным тестом вероятностей (generalized likelihood ratio test). Согласно другому методу, следует рассмотреть эти данные в качестве случайных переменных и по ним усреднить функции вероятностей. Этот метод называется тестом усредненных отношений вероятностей (average likelihood ratio test). В случае комбинации этих двух способов тест называется гибридным тестом отношений вероятностей (hybrid likelihood ratio test), который в основном применяется для заранее предвиденных видов модуляций, что и ограничивает применение таких классификаторов в "слепых" системах связи [3]. Кроме того, вероятность правильной классификации зависит от четкой последовательности особых ключевых характеристик принятого сигнала, подаваемых системе, что исключает возможность параллельной обработки, увеличивая время работы.

2. Вейвлет-преобразование. Вейвлет - это волноподобное колебание, амплитуда которой возрастает и снова снижается до нуля. Вейвлет-преобразование похоже на Фурье-преобразование в том смысле, что оно тоже разбивает сигнал на составные части. Фурье-преобразование разбивает временной сигнал на последовательность синусов разных частот и преобразовывает временной сигнал в частотный, а вейвлет-преобразование расширяет функции не как тригонометрические многочлены, а как вейвлеты, сгенерированные в виде расширенного и преобразованного материнского вейвлета. Иными словами, вейвлет-преобразование переводит сигнал из временного в частотно-временное представление, что позволяет извлечь из сигнала такие характеристики, какие невозможно извлечь иными способами. Вейвлеты очень эффективны для обработки нестационарных сигналов, а с точки зрения математики, они полезны, поскольку с их помощью возможно решить проблемы, связанные с Фурье-преобразованием [4].

Представим, что имеем функцию ψ , которая удовлетворяет следующим условиям:

$$\int_{-\infty}^{\infty} |\Psi(t)|^2 dt < \infty, \quad (1)$$

$$C_{\Psi} = 2\pi \int_{-\infty}^{\infty} \frac{|\Psi(\omega)|^2}{|\omega|} d(\omega) < \infty. \quad (2)$$

Здесь Ψ - это Фурье-преобразование функции ψ . Условие (1) обеспечивает конечность энергии функции ψ , а условие (2) обеспечивает, что $\Psi(0) = 0$ в случае, если $\Psi(\omega)$ - однородная функция. Функция ψ - это материнская вейвлет-волна.

2.1. Непрерывное вейвлет-преобразование. Если функция ψ удовлетворяет условиям (1) и (2), то вейвлет-преобразование функции $\psi(t)$ для реального сигнала $s(t)$ описывается следующим образом:

$$S(b, a) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} \psi' \left(\frac{t-b}{a} \right) s(t) dt. \quad (3)$$

Здесь ψ' - это комплексно-сопряженная функция ψ , которая принадлежит (b, a) открытой полуплоскости ($b \in \mathbf{R}$, $a > 0$). Параметр b соответствует временному сдвигу, а параметр a - масштабу анализирующего вейвлета. Если назначить $\psi_{a,b}(t)$ как

$$\psi_{a,b}(t) = a^{-\frac{1}{2}} \psi \left(\frac{(t-b)}{a} \right),$$

то уравнение (3) можно представить как скалярное произведение реального сигнала $s(t)$ и $\psi_{a,b}(t)$:

$$S(b, a) = \int_{-\infty}^{\infty} \psi'_{a,b}(t) s(t) dt.$$

Приняв, что функция $\psi(t)$ удовлетворяет условию (2), изначальный реальный сигнал можно получить обратным вейвлет-преобразованием:

$$S(t) = \frac{1}{C_{\psi}} \iint_{-\infty}^{\infty} S(b, a) \psi_{a,b}(t) \frac{da db}{a^2}.$$

2.2. Дискретное вейвлет-преобразование. В дискретной среде параметры масштабирования и временного сдвига дискретизированы как $a = a_0^m$ и $b = nb_0$, а анализирующий вейвлет - как:

$$\psi_{m,n}(t) = a_0^{-m/2} \psi\left(\frac{(t - nb_0)}{a_0^m}\right),$$

где m и n - целые числа. Дискретное вейвлет-преобразование и обратное дискретное преобразование описываются уравнениями

$$S(m,n) = \int_{-\infty}^{\infty} \psi'_{m,n}(t) s(t) dt \text{ и } S(t) = k_{\psi} \sum_m \sum_n S_{m,n} \psi_{m,n}(t).$$

Вейвлет-преобразование является методом извлечения особых ключевых характеристик сигнала, а не классификатором, поэтому этот метод комбинируется в алгоритмах с другими классификаторами [5-9].

3. Машина опорных векторов. МОВ (Support Vector Machine) является сравнительно новой обучающейся машиной, созданной в 1992г. Вапником [10]. МОВ имеют широкое применение при распознавании образов, в задачах расчета плотности вероятности и регрессии и т.д. Главной целью МОВ является увеличение расстояния между двумя самыми близкими точками, соответствующими данным двух разных классов. Чтобы линейно отделить две группы точек разных классов, нужно найти гиперплоскость. Для этого производится расчет максимального расстояния от двух самых близких точек. Эта гиперплоскость называется оптимальной гиперплоскостью (рис. 1).




Рис. 1. Оптимальная гиперплоскость

Изначально МОВ были разработаны для двоичной классификации, но реальные задачи в основном бывают для большого количества классов. Для классификации многих классов применяются разнообразные методы, например, Acyclic Graph (DAG), Binary Tree (BT), One-Against-One (OAO) и One-Against-All (OAA) [11].

Уравнение нелинейной классификации математически можно представить следующим образом:

$$g(\phi) = W \cdot K(\phi_{(x)} \cdot \phi_{(y)}) + b,$$

где $g(\phi)$ – функция классификации; W – нормальный вектор к гиперплоскости; $K(\phi_{(x)} \cdot \phi_{(y)})$ – функция Кernels; b – смещение (bias).

На рис. 2 показан принцип работы МОВ при нелинейной классификации. С помощью функции Кernels происходит переход из двумерного пространства в трехмерное, где уже возможно найти оптимальную гиперплоскость.




Рис. 2. Нелинейное разделение классов

МОВ предоставляет возможность применять разные функции Кernels в зависимости от задачи, что значительно увеличивает эффективность данного метода. Кроме того, параметр C гиперплоскости позволяет регулировать качество работы классификатора, т.е. при больших значениях параметра C неправильная классификация между точками данных сведена к минимуму, а при маленьких значениях точка, находящаяся далеко от группы точек своего класса, может быть игнорирована и неправильно классифицирована [12]. Тем самым появляется возможность регулировать чувствительность МОВ к шумам. У МОВ также имеются свои недостатки, например, проблема с двоичной классификацией, которая при большом количестве данных увеличивает длительность обучения. Также выбор правильной функции Кernels усложняет расчеты и увеличивает их длительность.

4. Искусственные нейронные сети. ИНС являются одним из наиболее распространенных и эффективных методов для МРО, поскольку с их помощью можно достичь хороших и точных результатов. Этот метод лежит в основе

одного из самых быстро развивающихся направлений технологии – машинного обучения (искусственный интеллект). Кроме того, ИНС применяются в таких разных приложениях, как медицинская диагностика, обработка сигналов, прогнозирование курса валюты, МРО и т.д. ИНС состоят из входного, скрытого/ых и выходного слоев. Каждый слой состоит из некоего количества нейронов, каждый из которых соединен с каждым нейроном следующего слоя. Принцип работы ИНС аналогичен работе нейронной сети головного мозга человека, т.е. с помощью нейронных связей ИНС распознает знакомые образы, данные, предметы и т.д., которые были "проанализированы" во время обучения. Иными словами, при входных данных, извлеченных из сигнала для определения конкретного образа, на выходе ИНС распознает данный образ на основе проведенных обучений и выдает соответствующие значения. Одно из самых главных преимуществ ИНС – это ее возможность самостоятельного обучения. Подробное описание ИНС и их принцип работы описаны в [13].

Кроме самостоятельного обучения, ИНС обладают рядом других преимуществ, как, например, возможность параллельной обработки данных, процентное представление правдивости распознавания, легкая перенастраиваемость в соответствии с данной задачей и т.д.

Закключение. Каждый метод или алгоритм разработан для решения конкретных задач и имеет свои особенности, проблемы реализации, преимущества и недостатки. С учетом этих критериев нужно выбрать такой метод, который будет наиболее подходящим и эффективным для решения задачи АРМ в среде графического программирования LabVIEW. Из двух основных типов методов: теоретического решения и распознавания образа, второй тип более подходит для решения данной задачи, поскольку у метода теоретического решения есть такие недостатки, как, например, расчеты функций плотности вероятности, конкретная последовательность подаваемых системе значений ключевых характеристик сигнала или предварительный расчет их пороговых значений, которые значительно ограничивают скорость и продуктивность алгоритма для данной задачи.

Применение вейвлет-преобразования для извлечения ключевых характеристик сигнала и его дальнейшая комбинация с другими классификаторами также нецелесообразны, так как алгоритмы вейвлет-преобразования сами по себе довольно комплексные и ресурсоемкие, а их применение в дополнение к классификатору приведет к затрате большого количества ресурсов.

Итак, предпочтение дается методу ИНС. Главным решающим фактором является свойство ИНС к самостоятельному обучению, что позволяет избежать сложных и длительных расчетов, дополнительного программиро-

вания для обучения и механического расчета пороговых значений ключевых характеристик сигнала. Разработка ИНС позволит обучить сеть очень большому количеству информации, что обеспечит очень точные результаты. Кроме того, ИНС можно перенастроить в соответствии с задачей, изменив количество скрытых слоев и/или нейронов, и тем самым увеличить скорость обучения и улучшить результаты. Последовательность ключевых характеристик, подаваемых входным нейронам сети, не влияет на точность распознавания, что обеспечивает параллельную обработку данных и тем самым сокращает длительность расчетов. И, наконец, ИНС являются основой искусственного интеллекта, что на данный момент представляет собой одно из самых развивающихся направлений технологии, обеспечивая перспективу для развития ИНС. Такое стремительное развитие данного технического направления предполагает, что в ближайшем будущем появятся возможности в несколько раз улучшить и усовершенствовать приложения, работающие на основе ИНС. Основываясь на вышеперечисленных преимуществах и особенностях, ИНС считается наиболее целесообразным, эффективным, быстрым, актуальным и перспективным методом для решения задачи АРМ.

СПИСОК ЛИТЕРАТУРЫ

1. **Azzouz E.E., Nandi A.K.** Automatic Modulation Recognition of Communication Signals. - Dordrecht, Kluwer Academic Publishers, 1996. – 214 p.
2. **Kumar H.L.P., Shrinivasan L.** Automatic Digital Modulation Recognition System Using Feature Extraction // Emerging trends in electrical, communications and information technologies.-Singapore, 2017. - Vol. 394. - P. 201-208.
3. **Zaihe Y.** Automatic modulation classification of communication signals. - August, 2006. - 231 p.
4. <http://www.hpl.hp.com/hpjournal/94dec/dec94a6.pdf>
5. **Hong L., Ho K.C.** Identification of digital modulation types using the wavelet transform // IEEE Military Communications. Conference Proceedings (Cat. No.99CH36341). - Atlantic City, NJ, 1999. - P. 427-431.
6. **Hossen A., Al-Wadahi F.** A Two-Stage Network for Modulation Classification Based on Entropy of Wavelet Transform // 3rd International Conference: SETIT. - Tunisia, 2005. – P. 5.
7. **Hassan K., Dayoub I., Hamouda W., Berbineau M.** Automatic Modulation Recognition Using Wavelet Transform and Neural Networks in Wireless Systems // EURASIP Journal on Advances in Signal Processing. - 2010. – P. 13.
8. **Faek F.K.** Digital Modulation Classification Using Wavelet Transform and Artificial Neural Network // Journal of Zankoy Sulaimani. – 2010. - Part A. – 13(1). – P. 59 – 70.
9. Automatic Modulation Recognition by Support Vector Machines Using Wavelet Kernel / **X.Z. Feng, J. Yang, F.L. Luo**, et al // Journal of Physics: Conference Series 48. - 2006. - P. 1264 – 1267.

10. **Vapnik V., Boser B., Guyon I.** A Training Algorithm for Optimal Margin Classifier // Proceedings of the Fifth Annual ACM Workshop on Computational Learning Theory. - 1996. - Vol. 5. - P. 144 – 152.
11. **Ren Q., Sun G., Zhang Y.** Modulation Mode Recognition Based On Multi-Class Classification of Support Vector Machine // Proceedings of the 2013 International Conference on Software Engineering and Computer Science. - 2013. - P. 150 – 154.
12. **Abe Sh.** Support vector machines for pattern classification // Springer-Verlag. – London, 2005. – P. 344.
13. **Гулян А.Г., Севоян О.Ж., Тантушян А.М.** Искусственные нейронные сети и их применение в автоматическом распознавании модуляций // Известия НАН РА и НПУА. Серия Техн. науки. - 2017. - Т. 70, №3. - С. 358-365.

Комитет по регулированию общественных услуг (КРОУ). Материал поступил в редакцию 10.04.2018.

Ա.Մ. ԹԱՆԹՈՒՇՅԱՆ

ՄՈԴՈՒԼԱՑՈՒՄՆԵՐԻ ԱՎՏՈՄԱՏԱՑՎԱԾ ՃԱՆԱՉՄԱՆ ՄԵԹՈԴՆԵՐԻ ՆԿԱՐԱԳՐՈՒԹՅՈՒՆԸ ԵՎ ԴՐԱՆՑ ՀԱՄԵՄԱՏԱԿԱՆ ՎԵՐԼՈՒԾՈՒԹՅՈՒՆԸ

Նկարագրված են մոդուլացումների ավտոմատացված ճանաչման մեթոդները, և ներկայացված է դրանց համեմատական վերլուծությունը, որը հնարավորություն է տալիս կատարել այս կամ այն մեթոդի հիմնավորված ընտրություն՝ LabVIEW գրաֆիկական ծրագրավորման միջավայրում հետագա անալոգային և թվային մոդուլացումների դեպքում ՄԱՃ խնդրի լուծման ալգորիթմ մշակելու համար:

Առանցքային բառեր. մոդուլացումների ավտոմատացված ճանաչման մեթոդներ, հիմնական բնութագրող հատկանիշներ, աջակցող վեկտորային մեքենաներ, արհեստական նեյրոնային ցանցեր:

A.M. TANTUSHYAN

METHODS OF AUTOMATIC MODULATION RECOGNITION AND THEIR COMPARATIVE ANALYSIS

Automatic modulation recognition methods are described and their comparative analysis is presented, allowing to make a justified choice of some method for the future development of an algorithm in the LabVIEW graphical programming environment for analogue and digital signals to solve the AMR problem.

Keywords: automatic modulation recognition methods, key features, support vector machines, artificial neural networks.