1.2 Априорная неопределенность в описании сигналов и помех

Априорная неопределенность в описании сигналов и помех понимается как отсутствие полного статистического описания модели событий и наблюдений (полной априорной информации), что не позволяет использовать классические методы синтеза и анализа алгоритмов обработки [8]. Она весьма характерна для ситуации, в которой находятся разработчики информационно-измерительных систем. Часто априорная неопределенность является следствием изменений условий функционирования системы в течение приема сигналов, нестационарности процессов (сигналов и помех).

Априорная неопределенность проявляется в том, что статистические гипотезы оказываются *сложными*, т. е. наблюдения y описываются *классами* вероятностных распределений, а не конкретными распределениями с известными параметрами, как в случае *простых* гипотез. Обнаружение и различение сигналов при сложных гипотезах можно рассматривать как *классификацию*, т. е. отнесение наблюдения к одному из заранее определенных классов. Однако задача классификации в общем случае включает также выбор или формирование *признаков* из первичных наблюдений [13].

Пусть гипотеза H_i есть предположение о принадлежности плотности вероятности наблюдения $f_i(y)$ к классу W_i, $i = 0, 1, \cdots, M-1$. Описание класса W_i может быть параметрическим или непараметрическим.

Параметрические модели наблюдений включают конечную совокупность параметров θ, так что $f_i(y) = f(y, \theta)$ при $\theta \in \Theta_i$. Под параметрами понимается конечное число констант, определяющих модель.

Разделение множества реализаций Y здесь заменяется разделением всего параметрического пространства Θ на непересекающиеся области Θ_i, так что $\Theta = \bigcup_{i=0}^{M-1} \Theta_i$. В этом случае говорят о *параметрической задаче* обработки. Среди параметров обычно можно выделить *полезные* (непосредственно связанные с событиями) и *мешающие* (не зависящие от событий). Неизвестные значения параметров модели приводят к *параметрической априорной неопределенности*.

Непараметрические модели отличаются тем, что каждый из классов W_i не может быть описан конечным множеством параметров, но характеризуется некоторым *свойством*, таким как симметрия, одинаковость формы распределений, однородность, статистическая независимость выборок и т. д. Задача различения сводится к разделению на непересекающиеся области непараметрического пространства $\mathrm{W} = \bigcup_{i=0}^{M-1} \mathrm{W}_i$. Априорная неопределенность при этом также является непараметрической.

Непараметрические гипотезы являются сложными по определению. Примером является в частности гипотеза о нормальности (гауссовости) распределения при произвольных значениях математического ожидания и дисперсии. Свойство нормальности означает равенство нулю всех (бесконечного числа) кумулянтов плотности, начиная с третьего.

В ряде случаев оптимальное (по некоторому критерию) решающее правило, полученное для простых гипотез, оказывается наилучшим и для некоторого *класса альтернативных гипотез*, т. е. *равномерно* наилучшим при сложной альтернативе. Решающее правило, сохраняющее наибольшую мощность в классе простых альтернатив, называется *равномерно наиболее мощным* (РНМ). Для РНМ алгоритма обнаружения априорная неопределенность, связанная с реализацией конкретной альтернативной гипотезы, будет *несущественной*. Она не меняет структуры оптимального алгоритма, хотя может влиять на показатель качества, т. е. быть *значимой*. Если же такого *решающего* правила нет, то априорная неопределенность, связанная с наличием класса альтернатив, будет *существенной*, влияющей на вид алгоритма.

С другой стороны, некоторый фактор или параметр, определяющий существенную априорную неопределенность, может оказаться *малозначимым*, т. е. слабо ухудшать показатели качества алгоритма (по сравнению с оптимальным алгоритмом в данной ситуации). Такой алгоритм оказывается *устойчивым* в определенном смысле или *малочувствительным* по отношению к указанному фактору. В работе [16] используется термин *степень критичности* к отклонениям от априорных данных.

Важной проблемой при синтезе алгоритмов в условиях априорной неопределенности является обеспечение устойчивости их характеристик по отношению к мешающим факторам при сохранении (или незначительном уменьшении) чувствительности к полезному сигналу по сравнению с классическими алгоритмами, полученными при полном описании сигналов и помех. В первую очередь стараются обеспечить малое изменение вероятности ложной тревоги (ВЛТ) при изменениях характеристик помехи.

Класс обнаружителей, обеспечивающих постоянство (стабилизацию) ВЛТ, называют CFAR-обнаружителями (Constant False Alarm Rate – постоянная частота ложных тревог). Условие постоянства ВЛТ при изменениях мешающих параметров является условием *подобия* критической области всему выборочному пространству. Если это свойство сохраняется для всех возможных распределений помехи, то такие алгоритмы называют *свободными от распределения* (distribution-free) [15].

Если распределения помехи образуют непараметрический класс, т. е. задаются некоторым свойством, то CFAR-обнаружитель (свободный от распределения) называется *непараметрическим.* В [6] предложено использовать термин «непараметрический» по отношению к задаче (гипотезе), а для метода решения задачи (и алгоритма) применять термин «свободный от распределения».

Использование *байесовского* критерия оптимальности (прил. 1) подразумевает случайный характер событий. Байесовский алгоритм использует большое число априорных сведений: матрицу потерь, априорные вероятности присутствия сигналов, распределения наблюдений при разных гипотезах.

Обычно элементы матрицы потерь неизвестны и оптимальное решение принимается по *максимуму апостериорной вероятности* (критерий *идеального наблюдателя Зигерта,* который полагает потери одинаковыми (единичными) при любых ошибках и нулевыми при каждом правильном решении [24]). В этом случае средний риск равен полной вероятности ошибки. Если к тому же неизвестны и априорные вероятности, то используется критерий *максимального правдоподобия*, который минимизирует суммарную вероятность ошибки [1].

Таким образом, частные байесовские критерии оптимальности позволяют сделать указанную априорную неопределенность несущественной. Использование критерия Неймана–Пирсона также позволяет избавиться от задания потерь и априорных вероятностей.

Однако в общем случае мешающие факторы и неточное задание параметров приводят к возрастанию вероятностей ошибок, увеличению среднего риска, причем равномерно наилучшее решающее правило обычно не существует.

Известны *специальные методы синтеза* алгоритмов в условиях неопределенности, основанные на принципах *адаптации, инвариантности* и *робастности*. *Адаптивные* алгоритмы обладают свойством перестраивать в процессе работы свои параметры и структуру в соответствии с изменяющейся сигнально-помеховой «обстановкой». Для этого они включают оценку па-

раметров этой неизвестной «обстановки». *Инвариантные* (от англ. invariant – неизменный) алгоритмы (по отношению к некоторому параметру или фактору) используют такие преобразования исходных наблюдений (инвариантные статистики), что результаты этих преобразований остаются неизменными при изменениях этого параметра или фактора. В то же время алгоритм должен сохранять чувствительность к изменению полезного параметра.

Инвариантные алгоритмы могут использовать как параметрические, так и непараметрические статистики. Полная инвариантность по отношению ко всем мешающим параметрам обычно трудно достижима. К тому же часто можно допустить некоторые небольшие вариации характеристик алгоритма. Слабая *чувствительность* к малым отклонения от модели может быть достигнута специальным «загрублением» алгоритма. При этом большие отклонения не должны приводить к катастрофическим последствиям. Такие алгоритмы называются *робастными* (от англ. robust – крепкий, здоровый, сильный [15]).

Робастность понимается как особый метод достижения устойчивости характеристик алгоритма при небольших изменениях в окрестности заданной параметрической модели. Иногда методы обеспечения робастности вместе с непараметрическими объединяются в «методы, свободные от распределения». Это показывает, что терминология в этой области находится еще в стадии становления [17].

Итак, при полной априорной информации о классах известно число классов, частные распределения для каждого класса, и вероятности появления соответствующих сигналов (при случайных событиях). Априорная неопределенность в описании модели не позволяет непосредственно использовать классические критерии и методы для получения алгоритмов обработки и определения характеристик. Для преодоления возникающих проблем нужны специальные методы синтеза алгоритмов в условиях неопределенности, основанные на принципах *адаптации*, *инвариантности* и *робастности.*