

## **Активное обучение классификатора режимов работы объекта с использованием имитационной модели**

**Дементий Ю.А.**, ООО «Релематика», Чебоксары, Российская Федерация. E-mail: dementiy.yu.a@gmail.com

***Аннотация:** В работе обсуждается проблема зависимости эффективности работы алгоритмов машинного обучения от информативности и количества имеющихся прецедентов, определяемых режимом работы объекта. Формулируется задача активного обучения с использованием имитационной модели объекта для синтеза наиболее информативных прецедентов. Рассматриваются вопросы сходимости процесса обучения моделей при таком подходе. Анализируется зависимость эффективности от параметров базового алгоритма классификации.*

***Ключевые слова:** машинное обучение, активное обучение, селективность, классификация режимов работы объекта.*

### ***Введение***

Обучение моделей классификации режимов работы объекта предполагает построение разграничивающей поверхности в наблюдаемом пространстве. Её форма и положение зависят только от структуры и допустимых диапазонов параметров объекта. Однако классические подходы к построению классификаторов демонстрируют зависимость итогового алгоритма от обучающих данных, доступных на момент построения. Кроме того, области режимов в наблюдаемом пространстве могут пересекаться, что является причиной существования различных разделяющих кривых для одного набора данных, соответствующих различным ограничениям на решение задачи. Это обуславливает необходимость разработки метода построения классификаторов, для которого входными данными будут являться модель объекта и диапазоны ее параметров, а не заранее сформированная обучающая выборка.

### ***Задача***

В работе рассматривается подход к решению группы задач, в которых имеет место приоритет классификации одного режима над другим. То есть в случае, когда один и тот же набор

наблюдаемых значений может соответствовать различным классам (точка в наблюдаемом пространстве находится на пересечении областей режимов), ответ классификатора соответствует приоритетному классу.

Задачи из этого класса в общем виде можно описать следующим образом. Пусть имеются имитационные модели двух режимов работы объекта ( $\alpha$  - и  $\beta$  -режимов), описываемые функциями  $F_\alpha, F_\beta$ , отображающими соответствующие множества (области)  $G_\alpha, G_\beta \subset C$  векторов объектного пространства во множества векторов наблюдаемого пространства  $S_\alpha, S_\beta$ . Векторы из множеств  $S_\alpha, S_\beta$  являются элементами одного общего наблюдаемого пространства  $A$ . Области  $G_\alpha, G_\beta$  являются  $m$ -мерными гиперпрямоугольниками, определенными векторами, компонентами которых являются максимальные и минимальные значения объектных параметров  $\mathbf{x}_{\min} = [x_{1\min} \dots x_{m\min}]$ ,  $\mathbf{x}_{\max} = [x_{1\max} \dots x_{m\max}]$ . Требуется на основании имеющихся моделей  $F_\alpha, F_\beta$  и векторов  $\mathbf{x}_{\min}, \mathbf{x}_{\max}$  построить (обучить) классификатор  $a(\mathbf{v})$  векторов  $\mathbf{v} \in S_\alpha \cup S_\beta$  так, чтобы, при определении класса  $\beta$  -режимов приоритетным, выполнялись условия (1) и (2).

$$TPR_\beta(a | S_\alpha, S_\beta) = 1 \quad (1)$$

Где  $TPR$  – true positive rate или метрика полноты классификации;  $a$  – алгоритм классификации.

$$PPV_\beta(a | S_\alpha, S_\beta, TPR_\beta = 1) \rightarrow \max \quad (2)$$

Где  $PPV$  – positive predictive value или метрика точности классификации.

### ***Активное обучение классификатора***

Предлагаемый подход основан на концепции активного обучения [1]. Он представляет собой итерационный поиск наиболее информативных векторов  $\mathbf{v} \in S_\alpha \cup S_\beta$  и использование их в качестве обучающей выборки для получения  $a(\mathbf{v})$ , удовлетворяющего условиям (1) и (2).

Поиск векторов происходит в объектном пространстве  $C$ .

Это обусловлено тем, что прямоугольная форма областей  $G_\alpha, G_\beta$  делает проверку попадания точки в одну них тривиальной задачей, тогда как форма областей  $S_\alpha, S_\beta$  заранее неизвестна и определена имитационными моделями и их диапазонами допустимых объектных параметров. Таким образом, алгоритм активного обучения ищет наиболее информативные точки в наблюдаемом пространстве и пытается получить новые информативные точки рядом с ними. При этом нет возможности создавать новые точки прямо в наблюдаемом пространстве, так как в таком случае невозможно проверить соблюдение ограничений, накладываемых задачей на объектные параметры. Формирование новых точек выполняется в пространстве  $C$ , с последующим их отображением имитационными моделями в  $A$ . Такой подход позволяет отказаться от заранее сформированной обучающей выборки и использовать имитационные модели объектов как основные источники информации для обучения классификатора.

Поиск может выполняться как с применением методов стохастической оптимизации, так и с использованием методов локальной оптимизации на основе частных производных на основании заранее определённых критериев информативности и критерия останова обучения, выбираемых исходя из особенностей модели классификации.

### ***Критерии информативности и сходимости***

Информативность может быть выборочной и точечной. Точечная (условная) информативность является мерой влияния точки на форму и положение поверхности, разделяющей режимы в наблюдаемом пространстве. Она зависит от текущих параметров обучаемого классификатора (полученных в результате обучения на предыдущей итерации) и текущего количества и расположения точек обучающей выборки. Выборочная (безусловная) информативность является способностью обучающей выборки как множества точек характеризовать форму, размеры и положение областей  $S_\alpha, S_\beta$ .

Максимальной информативности выборка достигает только тогда, когда она состоит из бесконечного количества точек,

равномерно распределенных в пространстве внутри областей  $S_\alpha, S_\beta$ , в том числе равномерно заполняющих границы областей. Такие выборки, очевидно, являются невозможными и целесообразно говорить о выборках, информативность которых только стремится к максимальной.

Генерация новых точек, объединение их в единую обучающую выборку и фильтрация выборки на основании точечной информативности увеличивает безусловную информативность выборки. В процессе обучения классификатора на каждой итерации происходит дообучение модели на выборке, имеющей увеличенную по сравнению с прошлой итерацией информативность. Этот процесс приводит к постепенному замедлению роста выборочной информативности, что говорит о сходимости обучения.

Однако, высокая сложность алгоритма классификации (количество степеней свободы разделяющей кривой) может привести к тому, что даже достаточно высокая выборочная информативность не гарантирует выполнение условия (1) вследствие недостаточной плотности точек. В такой ситуации возможна генерация новых условно информативных точек, заполняющих пустоты и повышающих плотность. Таким образом, скорость роста выборочной информативности не должна являться основным признаком того, что сходимость достигнута. Общий критерий остановки обучения должен основываться на скорости нарастания выборочной информативности и результативности поиска точек с высокой условной информативностью.

Одним из аспектов анализа сходимости является анализ сложности алгоритма классификации. В случае её дефицита сходимость обучения к результату, обеспечивающему выполнение условия (2) однозначно невозможна. При этом на основании сформулированного выше требования к общему критерию остановки, можно говорить о том, что завышенная сложность алгоритма не приводит к эффекту переобучения, являющемуся одной из главных проблем обучения по прецедентам [2]. Однако завышение сложности может привести к существенному замедлению сходимости. В качестве общего

решения этой проблемы возможно использование механизма регуляризации совместно с завышенной сложностью алгоритма классификации.

### ***Заключение***

Задача построения классификатора режимов работы объекта в общем случае не может быть решена с использованием прецедентов как основного источника информации. В качестве такого источника целесообразно использовать имитационные модели режимов объекта.

Отбор информации, получаемой из имитационных моделей, производится на основании информативности, оцениваемой как для точек, так и для обучающей выборки в целом. Критерии информативности могут быть определены произвольно в зависимости от задачи и особенностей модели классификации.

Сходимость процедуры обучения, основанной на предлагаемом подходе, возможна для классифицирующих моделей достаточной сложности. При этом правильно выбранные критерии информативности и критерий остановки обучения позволяют избежать проблемы переобучения модели даже в случае значительного завышения её сложности.

### **СПИСОК ЛИТЕРАТУРЫ**

1. *Balcan MF., Urner R. (2016) Active Learning – Modern Learning Theory. In: Kao MY. (eds) Encyclopedia of Algorithms. Springer, New York, NY. [https://doi.org/10.1007/978-1-4939-2864-4\\_769](https://doi.org/10.1007/978-1-4939-2864-4_769)*

2. *Миронов, А. М. Машинное обучение [Текст]: учебное пособие / А. М. Миронов; Московский государственный университет имени М. В. Ломоносова, Механико-математический факультет, Кафедра математической теории интеллектуальных систем. - Москва : МАКС Пресс, 2018.*

*Авторы:*

***Дементий Юрий Анатольевич***, к.т.н, руководитель группы ООО «Релематика». Окончил электроэнергетический факультет Вологодского государственного университета в 2015 г. В 2018 защитил кандидатскую диссертацию на тему «Методы и средства компенсации полного тока однофазного замыкания на землю в распределительных сетях». E-mail: dementiу.yu.a@gmail.com