

УДК 621.31

АНАЛИЗ ПРИМЕНЕНИЯ МЕТОДА ОПОРНЫХ ВЕКТОРОВ В МНОГОМЕРНОЙ РЕЛЕЙНОЙ ЗАЩИТЕ

© 2020 г. А. Л. Куликов¹, Д. И. Бездушный¹, *, М. В. Шарыгин¹, В. Ю. Осокин¹

¹Нижегородский государственный технический университет, Нижний Новгород, Россия

*e-mail: dimok.93@mail.ru

Поступила в редакцию 11.02.2020 г.

После доработки 25.02.2020 г.

Принята к публикации 27.02.2020 г.

Цифровая трансформация электроэнергетики, использование различных интеллектуальных электронных устройств (ИЭУ), высокоскоростных протоколов коммуникаций создают широкие возможности для модернизации систем релейной защиты (РЗ) электроэнергетических объектов. Одним из перспективных направлений ее развития является разработка новых устройств РЗ, принцип работы которых основан на элементах искусственного интеллекта и машинного обучения. В статье рассматриваются особенности применения одного из распространенных алгоритмов машинного обучения — метода опорных векторов — на примере построения трехмерного пускового органа, служащего для повышения селективности функционирования ступенчатой защиты линии электропередачи. Предлагаемый пусковой орган обладает высокой способностью и простотой технической реализации в составе ИЭУ РЗ.

Ключевые слова: многомерная релейная защита, метод опорных векторов, метод Монте-Карло, дистанционная защита, принцип максимального правдоподобия

DOI: 10.31857/S0002331020020065

Современные электроэнергетические системы представляют собой технически сложные комплексы, состоящие из большого количества взаимосвязанных элементов. При этом, как производители, так и потребители электрической энергии предъявляют все более жесткие требования к надежности электроснабжения. В процессе интеллектуализации электроэнергетики важнейшую роль играет совершенствование релейной защиты, цель которой состоит в отключении поврежденных элементов и участков электрической сети. Современные терминалы РЗА помимо функций защиты, выполняют функции управления, регистрации, осциллографирования и др., участвуя в обмене данными с другими устройствами, находящимися на подстанции и за ее пределами, посредством систем сбора и передачи информации (ССПИ) [1]. В частности, внедрение протокола МЭК 61850 предполагает наличие единой внутриподстанционной системы передачи данных не только для устройств РЗ, но и других систем автоматизации [2]. Это открывает устройствам РЗ доступ к большому объему информации о защищаемом объекте в режиме реального времени. К сожалению, основные алгоритмы РЗ за последние десятилетия принципиально не изменились и, по сути, являются цифровыми аналогами своих электромеханических предшественников [3, 4].

Перспективен подход к организации РЗ, основанный на множественном имитационном моделировании и статистической обработке результатов имитационных экспериментов [например, 4–9]. В частности, для реализации функций распознавания режимов электрической сети целесообразно применение машинного обучения [10–12].

Использование такого подхода для организации защиты электроэнергетических объектов потенциально несет в себе следующие преимущества:

- признаки, на основе которых принимается решение о срабатывании РЗ, могут быть индивидуальными для каждого энергетического объекта и подбираться из условия максимальной информативности процесса распознавания. Поскольку алгоритмы машинного обучения предполагают многомерную реализацию, количество признаков для каждой РЗ может быть произвольным и ограничиваться лишь вычислительной способностью используемого цифрового устройства (терминала защиты);

- выбор параметров срабатывания РЗ связан с процедурой обучения распознающего алгоритма на совокупности реализаций, описывающих поведение защищаемого объекта в нормальных и аварийных режимах. Требуемые реализации могут быть получены как по результатам имитационного моделирования, так и непосредственно во время эксплуатации. Такой подход позволяет защите адаптироваться к условиям эксплуатации в режиме реального времени (самообучаться).

Алгоритмы машинного обучения могут применяться не только в составе процедур принятия решения РЗ, но и в составе пусковых органов, дополняющих традиционные виды защиты и обеспечивающих улучшение их основных характеристик (быстродействия, селективности, чувствительности). Ниже приводится пример разработки специального пускового органа для дистанционной защиты линии электропередач, на основе одного из наиболее простых и наглядных, но в то же время эффективных [11, 12] методов машинного обучения — метода опорных векторов (англ. — *SVM, support vector machine*).

Принципы применения метода опорных векторов. Задачи, решаемые при помощи машинного обучения, могут быть разделены на два класса: задачи классификации и регрессии. Задача регрессии заключается в восстановлении вида некоторой функции $F(x)$ по имеющейся эмпирической информации о значениях $F_1...F_n$, принятых этой функцией при аргументах $x_1...x_n$. Задача классификации состоит в отнесении некоторого вектора признаков x к одному из классов $Y_1...Y_m$ на основе обучающей выборки, состоящей из набора векторов $x_1...x_n$, для которых известно, к каким классам они относятся. Как можно видеть, задача РЗ очень близка к задаче классификации и может быть сформулирована в терминах машинного обучения. В этом случае классификации подлежит вектор, состоящий из параметров токов и напряжений, оцененных измерительными органами РЗ (токи, напряжения и т.д.), а классы соответствуют режимам работы защищаемого объекта (нормальный режим, короткое замыкание в зоне защиты, короткое замыкание вне зоны защиты и т.д.).

В наиболее простом виде метод опорных векторов применяется для распознавания двух классов (например, нормальный или аварийный режим), а процедура принятия решения включает проведение в пространстве признаков гиперплоскости, которая будет разделять между собой элементы, относящиеся к разным классам, и находится при этом максимально далеко от представителей обоих классов.

Пусть имеется обучающая выборка $x_1...x_N$, состоящая из N векторов, расположенных в M -мерном пространстве признаков. Для каждого элемента обучающей выборки имеется метка класса $y_1...y_N$ такая, что $y_i = 1$, если i -тый элемент принадлежит к одному классу (обозначим его как класс α) и $y_i = -1$, если i -тый элемент принадлежит к другому классу (обозначим его как класс β). Тогда, если данная выборка линейно разделима, то можно провести гиперплоскость, такую, что все точки, принадлежащие классу α , будут лежать по одну сторону от нее, а все точки, принадлежащие классу β — по другую. Уравнение гиперплоскости можно записать в виде

$$Q(a) = w^T \cdot a + b = 0, \quad (1)$$

где w , b — коэффициенты, задающие гиперплоскость; a — вектор, описывающий произвольную точку в пространстве признаков, в котором строится гиперплоскость.




Рис. 1. Различные варианты размещения разделяющих гиперплоскостей.

Если гиперплоскость действительно разделяет точки обучающей выборки, то справедливо следующее неравенство

$$\forall i \in 1 \dots N, y_i \cdot (\mathbf{w}^T \cdot \mathbf{x}_i + b) > 0. \quad (2)$$

В общем случае, гиперплоскость, удовлетворяющая (2) не единственна. На рисунке 1 изображены точки обучающей выборки, относящиеся к двум классам, а также два варианта размещения разделяющей гиперплоскости (**a** и **b**). Поскольку пример (рис. 1) приведен для двухмерного пространства, гиперплоскости вырождаются в прямые. Несмотря на то, что обе гиперплоскости успешно разделяют классы между собой, из рис. 1 видно, что вариант (**a**) более подходит для классификации предложенных данных, так как обеспечивает большую ширину полосы между представителями различных классов. Ширину полосы принято называть зазор (англ. *margin*). Таким образом, метод опорных векторов позволяет отыскать гиперплоскость, обеспечивающую максимальный зазор между классами.

Доказано [11], что уравнение гиперплоскости, обеспечивающей максимальный зазор, может быть получено в результате отыскания условного минимума системы выражений

$$\begin{cases} \min_{\mathbf{w}_n, b_n} \frac{1}{2} \mathbf{w}_n^T \cdot \mathbf{w}_n, \\ \forall i \in 1 \dots N, y_i \cdot (\mathbf{w}_n^T \cdot \mathbf{x}_i + b_n) \geq 1. \end{cases} \quad (3)$$

Однако, в большинстве практических случаев, обучающая выборка не является линейно separable, то есть не существует ни одной гиперплоскости, удовлетворяющей




Рис. 2. Работа *SVM* при различных значениях коэффициента C : (а) $C = 10$; (б) $C = 1$.

системе неравенств (2). Для того, чтобы алгоритм *SVM* мог быть применен в таком случае, он подлежит модификации и допускает некоторую неправильную классификацию объектов обучающей выборки. За суммарную ошибку классификации вводится штраф, а задача оптимизации принимает вид

$$\begin{cases} \min_{\mathbf{w}_H, b_H, \xi_1, \dots, \xi_N} \frac{1}{2} \mathbf{w}_H^T \cdot \mathbf{w}_H + C \sum_{i=1}^N \xi_i, \\ \forall i \in 1 \dots N, \quad y_i \cdot (\mathbf{w}^T \cdot \mathbf{x}_i + b) \geq 1 - \xi_i, \\ \forall i \in 1 \dots N, \quad \xi_i \geq 0, \end{cases} \quad (4)$$

где ξ_i — переменная, характеризующая ошибку классификации i -го объекта обучающей выборки; C — коэффициент, устанавливающий величину штрафа за неверную классификацию.

Коэффициент C позволяет регулировать, что для алгоритма будет более важно — максимизация ширины разделяющей полосы, или минимизация суммарной ошибки классификации. Рисунок 2 демонстрирует влияние значения данного коэффициента на поведение алгоритма. Как можно видеть, при большом значении C алгоритм не допускает неверной классификации точек, несмотря на узкую разделяющую полосу, в то время как при малом значении, разделяющая полоса существенно шире, однако одна из точек обучающей выборки классифицируется неверно.

На практике, вместо прямой задачи *SVM*, описываемой выражением (4), решается так называемая двойственная задача, которая аналогична исходной, с точки зрения конечного ответа, однако, может быть решена с применением более быстрых итерационных методов. При решении двойственной задачи *SVM*, оптимизация происходит по переменным $\lambda_1 \dots \lambda_n$ (выражение (5)), то есть по множителям Лагранжа. Двойственная задача *SVM* для линейно-неразделимой выборки выводится из прямой задачи [10] и записывается в следующем виде

$$\begin{cases} \min_{\lambda_1, \dots, \lambda_n} \left(\sum_{i=1}^n \lambda_i - \frac{1}{2} \cdot \left(\sum_{i=1}^n \sum_{j=1}^n \lambda_i \lambda_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j \right) \right), \\ \forall i \in 1 \dots N, \quad 0 \leq \lambda_i \leq C, \\ \forall i \in 1 \dots N, \quad \lambda_i y_i = 0. \end{cases} \quad (5)$$




Рис. 3. Схема рассматриваемого участка сети.

Задача квадратичного программирования (5) может быть решена при помощи одного из известных методов [например, 12].

Получив оптимальные множители Лагранжа $\lambda_1 \dots \lambda_n$ в результате решения (5), можно восстановить уравнение разделяющей гиперплоскости

$$\mathbf{w} = \sum_{i=1}^n \lambda_i y_i \mathbf{x}_i, \quad b = \frac{1}{y_s} - \mathbf{w} \cdot \mathbf{x}_s, \quad (6)$$

где s — индекс вектора, для которого $0 < \lambda_s < C$.

Алгоритм классификации может быть выражен через коэффициенты $\lambda_1 \dots \lambda_n$ следующим образом

$$a(\mathbf{x}) = \text{sign} \left(\sum_{i=1}^n \lambda_i y_i \mathbf{x}_i^T \mathbf{x} - b \right). \quad (7)$$

Отметим, что для корректной работы классификатора, описываемого выражением (7) достаточно провести суммирование только по тем i , для которых $\lambda_i \neq 0$, т.е. только по опорным векторам, количество которых гораздо меньше общего размера обучающей выборки.

Применение метода опорных векторов в задачах релейной защиты. Рассмотрим пример использования *SVM* алгоритма для увеличения распознающей способности релейной защиты. Пусть имеется комплект релейной (дистанционной) защиты, установленный на линии ω_1 участка сети на рис. 3.

В основную зону данного комплекта входит вся линия ω_1 , а в резервную — участки линий ω_2 и ω_3 , прилегающие к ПС Б. При этом, для обеспечения требуемой чувствительности, необходимо, чтобы короткие замыкания на линиях ω_2 и ω_3 отключались отдельными ступенями, имеющими отличные друг от друга уставки. Обозначим их как “Ступень ω_2 ” и “Ступень ω_3 ” соответственно. Такое разбиение резервной зоны между двумя ступенями позволит выбрать более чувствительные уставки для каждой из них, не приводя к неселективному действию защиты в резервной зоне. Данные ступени должны быть отстроены по времени от быстродействующих ступеней резервируемых ими защит на ступень селективности (0.5 с.).

Многочратно промоделируем короткие замыкания на линиях ω_2 и ω_3 в соответствии с методом Монте-Карло [13] и зафиксируем параметры режима (токи и напряжения), наблюдаемые в месте установки защиты в виде комплексных значений.




Рис. 4. Множество результатов имитационных экспериментов.




Рис. 5. Логика совместной работы дистанционного органа и органа, функционирующего в соответствии с методом опорных векторов.

Анализ полученных модельных данных показывает, что на комплексной плоскости активного и реактивного замеров сопротивления, множество коротких замыканий на линиях ω_2 и ω_3 различной удаленности и с различным значением переходного сопротивления расположится так, как показано на рис. 4.

Как можно видеть, практически все короткие замыкания на ω_3 находятся в области “перекрытия” и не могут быть однозначно идентифицированы. Очевидно, что на рассматриваемой уставочной плоскости не удастся выбрать такие характеристики срабатывания ступеней, чтобы одна из них срабатывала при КЗ только на ω_2 , а другая — только на ω_3 .

Воспользовавшись методом опорных векторов, разработаем дополнительный пусковой орган, который будет срабатывать при КЗ на ω_3 и блокироваться при КЗ на ω_2 . Логика совместной работы пускового органа и комплекта дистанционной защиты показана на рис. 5.

В качестве информационных признаков для функционирования дополнительного пускового органа выберем активный (R) и реактивный (X) замеры сопротивления, а




Рис. 6. Разброс данных имитационных экспериментов в трехмерном пространстве признаков.




Рис. 7. Обучающая выборка.

также ток параллельной линии ($I\omega_2$), измеренный на стороне, на которой установлена проектируемая защита (рис. 3). Объединим выбранные признаки в единое трехмерное пространство. Разброс значений указанных параметров в соответствующем пространстве признаков показан на рис. 6.

Поскольку разрабатываемый пусковой орган функционирует совместно с двумя ступенями комплекта дистанционной защиты, с целью увеличения точности алгоритма и снижения временных затрат на обучение, возможно ограничить обучающую выборку лишь теми модельными экспериментами, в которых возможно срабатывание хотя бы одной из данных ступеней. По данной причине нецелесообразно включать в




Рис. 8. Распределения условных плотностей вероятностей признаков.




Рис. 9. Разделяющая плоскость, полученная в результате работы метода опорных векторов.

обучающую выборку результаты моделирования режимов, в которых данные ступени заведомо не работают (КЗ “за спиной”, нормальные режимы).

Таким образом, выполним обучение алгоритма на экспериментах с короткими замыканиями на части линии ω_3 , которая входит в зону защиты “ступени ω_3 ” (обозначим их как α -режимы), и противопоставим им короткие замыкания на части линии ω_2 , входящей в зону защиты “ступени ω_2 ” (обозначим их как β -режимы). Точки в пространстве признаков, вошедшие в обучающую выборку, представлены на рис. 7.

Выясним, насколько каждый из выбранных признаков эффективен в отдельности для решения поставленной задачи классификации. На рисунке 8 показаны статистические распределения каждого из выбранных признаков в α - и β -режимах.

С учетом каждого из признаков построим одномерные классификаторы, принимающие решения по одной из двух гипотез: “КЗ на ω_2 ” и “КЗ на ω_3 ”, в зависимости от значения признаков. Решающее правило одномерных классификаторов реализуем по критерию максимального правдоподобия [например, 14]. Каждый из классификаторов будет выбирать ту гипотезу, при которой, наблюдаемое значение отслеживаемого

Таблица 1. Вероятности ошибок классификации одномерных классификаторов

R	X	$I\omega_2$
40.32%	41.21%	4.79%

Таблица 2. Матрица ошибок работы разрабатываемого пускового органа

		Результаты работы алгоритма SVM	
Фактический режим	α -режим	α -режим	β -режим
		100%	0%
	β -режим	0.03%	99.97%

им признака более вероятно. Таблица 1 показывает, какую вероятность ошибки обеспечивает каждый из признаков при его использовании в соответствующем классификаторе. Так вероятность правильного распознавания анализируемых режимов по признакам активного R и реактивного X сопротивлений лишь немногим превышает такую при выборе ответа “наугад”.

Реализуем процедуру “обучения” алгоритма SVM с линейной функцией ядра [8] и коэффициентом $C = 100$ на предварительно полученной выборке. Полученную в результате обучения разделяющую плоскость изобразим на рис. 9.

Эффективность работы полученного алгоритма может быть продемонстрирована при помощи матрицы ошибок (табл. 2), в которую сведены вероятности правильной работы алгоритма, а также вероятности ошибок первого и второго рода.

Алгоритм распознавания на основе SVM , реализуемый для специального пускового органа РЗ, характеризуется ошибкой, не превышающей 0.03%, что значительно меньше, чем может обеспечить самый эффективный из одномерных классификаторов. Таким образом, рассмотренный пример подтверждает, что объединение информационных признаков РЗ в единое многомерное признаковое пространство позволяет добиться значительного выигрыша при распознавании режимов в задачах защиты электрических сетей.

ЗАКЛЮЧЕНИЕ

1. Цифровизация энергетики, в частности, релейной защиты, сделала возможным применение принципиально нового подхода к построению РЗ, основанного на имитационном моделировании и машинном обучении.

2. Перспективно применение метода опорных векторов в задачах РЗ как при формировании новых алгоритмов защиты, так и в качестве дополнительного инструмента повышения селективности и быстродействия существующих видов защит.

3. Несмотря на то, что увеличение размерности пространства признаков с целью повышения точности распознавания является традиционным приемом, применяемым в задачах классификации, построение многомерных алгоритмов релейной защиты — это новое перспективное направление, требующее дальнейшего развития.

4. Объединение информационных признаков в многомерное признаковое пространство позволяет реализовать классификатор, имеющий большую вероятность правильного распознавания, чем при использовании информационных признаков в отдельности.

СПИСОК ЛИТЕРАТУРЫ

1. Лизунов И.Н. Технологии передачи данных в современных системах релейной защиты и автоматизации и их показатели качества / И.Н. Лизунов, А.Н. Васев, Р.Ш. Мисбахов // Известия высших учебных заведений. Проблемы энергетики. 2017. № 1–2. С. 52–63.
2. Adamiak M. IEC 61850 communication networks and systems in substations: An overview for users / M. Adamiak, D. Baigent, R. Mackiewicz // Prot. Control J. 2009. P. 61–68.
3. Шнеерсон Э.М. Цифровая релейная защита / Э.М. Шнеерсон. М.: Энергоатомиздат, 2007. 549 с.
4. Шарыгин М.В. Защита и автоматика систем электроснабжения с активными промышленными потребителями // Шарыгин М.В., Куликов А.Л. Нижний Новгород: НИУ РАНХиГС, 2017. 286 с.
5. Куликов А.Л., Шарыгин М.В. Применение статистических критериев распознавания режима релейной защиты сетей электроснабжения // Электротехника. 2019. № 2. С. 58–64.
6. Бездушный Д.И., Куликов А.Л. Формирование обобщенных признаков срабатывания релейной защиты на основе метода главных компонент // Релейная защита и автоматизация. 2019. Т. 34. № 1. С. 20–27.
7. Шарыгин М.В., Куликов А.Л. Статистические методы распознавания режимов в релейной защите и автоматике сетей электроснабжения // Электрические станции. 2018. № 2(1039). С. 32–39.
8. Ван-Трис Г. Теория обнаружения, оценок и модуляции. Т.1: Теория обнаружения, оценок и линейной модуляции: пер. с англ. под ред. проф. В.И. Тихонова / Г. Ван-Трис. М.: Советское радио, 1972. 744 с.
9. Gose E. Pattern recognition and image analysis. Upper Saddle River: Prentice Hall PTR, 1997. 484 p.
10. Bishop C.M. Pattern Recognition and Machine Learning. Berlin: Springer, 2006. 738 p.
11. Wang L. Support Vector Machines: Theory and Applications. Berlin: Springer, 2005. 28 p.
12. Bottou L. Support Vector Machine Solvers / L. Bottou, C-J. Lin // Large Scale Kernel Machines. 2007. № 1. С. 1–28.
13. Ермаков С.М. Метод Монте-Карло в вычислительной математике: Вводный курс / С.М. Ермаков. Санкт-Петербург: 2009. 192 с.
14. Зюко А.Г. Теория передачи сигналов / А.Г. Зюко, Д.Д. Кловский, М.В. Назаров. М.: Радио и связь, 1986. 304 с.

The Support Vector Machine Application Analysis in Multidimensional Relay Protection

A. L. Kulikov^a, D. I. Bezdushniy^{a, *}, M. V. Sharygin^a, and V. Yu. Osokin^a

^aNizhny Novgorod State Technical University, Nizhny Novgorod, Russia

*e-mail: dimok.93@mail.ru

Power engineering digital transformation, the use of different intelligent electronic devices (IEDs), high-speed communication protocols provide extensive opportunities for relay protection and automation systems modernization of power utilities. One of the most promising avenues of power engineering development is design of new protection devices, whose principles are based on the elements of artificial intelligence and machine learning. The article discusses the features of the application of one of the most common machine learning algorithms, the support vector machine, by the example of constructing a three-dimensional fault detector, which would serve to increase a transmission line stepped protection selectivity. The proposed fault detector has high recognition ability and ease of technical implementation as part of the protection IED.

Keywords: multidimensional relay protection, support vector machine, Monte Carlo method, distance relay, maximum likelihood estimation