

НЕЙРОСЕТЕВАЯ КЛАССИФИКАЦИЯ РЕЖИМОВ РАБОТЫ ОБЪЕКТА

Дементий Ю. А., ООО «Релематика», г. Чебоксары, Россия, dementiy.yu.a@gmail.com.

Маслов А.Н., ООО «Релематика», г. Чебоксары, Россия, maslov.a.n@list.ru

Николаев К. П., ООО «Релематика», г. Чебоксары, Россия, nikolaev.kirill.p@mail.ru

***Аннотация:** В работе показано решение задачи классификации режимов работы объекта с использованием нейросетевого алгоритма. Обсуждаются статистическая и геометрическая интерпретации алгоритмов. Показана зависимость качества работы от распределения прецедентов, на основании которых производится обучение, а также от структуры и параметров нейронной сети. Показаны пределы применимости подобных алгоритмов для задачи классификации режимов работы объекта в электроэнергетике и сформулированы рекомендации для практического их применения.*

***Ключевые слова:** машинное обучение, нейронная сеть, классификация режимов работы объекта.*

Введение

Основной задачей релейной защиты является выявление аварийных режимов работы энергообъекта, однако, для принятия решения об отключении необходимо также определить является ли наблюдаемый аварийный режим следствием повреждения защищаемого участка или же повреждение произошло на его смежной части. Таким образом, релейная защита выполняет классификацию режимов работы энергообъекта. Простейшим классификатором является токовая отсечка, разграничивающая режимы работы только по величине наблюдаемого тока. Более сложным классификатором является реле сопротивления дистанционной защиты, проверяющее попадание замера сопротивления в заданный полуголон.

Нейросетевая классификация режимов

Для всех широко применяемых алгоритмов релейной защиты существуют руководящие указания по расчёту уставок. Эти методики позволяют выбрать параметры срабатывания защит на основе информации о структуре и параметрах

защищаемого объекта. Предполагается, что нейросетевой принцип способен классифицировать режимы работы энергообъекта, однако в данный момент неясно как выполнить обучение нейронной сети используя ту же информацию, которая используется для расчёта параметров классических алгоритмов. Для обучения нейронной сети, то есть в общем случае для решения многопараметрической задачи нелинейной оптимизации используются наборы данных (датасеты). Применительно к задаче классификации режимов работы энергообъекта в роли таких данных выступают токи и напряжения, наблюдаемые в месте установки защиты, для которых точно известно – относится наблюдаемый режим к повреждению защищаемого участка или повреждению смежного. Возникает вопрос – как получить наиболее информативный набор данных, который позволит обучить нейронную сеть с гарантированной селективностью.

Обучение на прецедентах

Пусть имеется линия с двухсторонним питанием, на которой в течение долгого промежутка времени фиксировались значения токов и напряжений в режимах короткого замыкания. Кроме этого, отмечалось к какому классу относится каждый режим – внешнее или внутреннее короткое замыкание. Сгенерируем эти данные с помощью математической модели такой линии, для которой все параметры примем фиксированными, а варьировать будем лишь угол передачи линии δ , расстояние до места повреждения x_f , а также величину переходного сопротивления в месте повреждения R_f . Угол передачи линии, а также место повреждения берутся случайным образом согласно равномерному распределению. Величина переходного сопротивления берётся случайным образом согласно логарифмическому распределению из предположения, что наиболее часто встречающиеся короткие замыкания металлические.

Отобразим на комплексной плоскости замера сопротивления \underline{Z} красными точками прецеденты, соответствующие коротким замыканиям в пределах защищаемого участка, синими точками – вне защищаемого участка (рис. 1). Зелёная линия показывает истинную границу, в

пределах которой могут находиться все теоретически возможные прецеденты, соответствующие внешним коротким замыканиям для рассматриваемой модели линии.

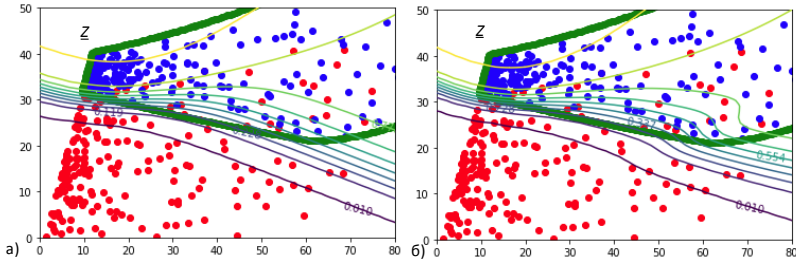


Рис. 1. Отображение прецедентов и граничной линии на комплексной плоскости: *a* – изолинии для нейронной сети с 15 нейронами, *б* – изолинии для нейронной сети с 30 нейронами

Используя полученные данные (по 200 прецедентов для каждого класса) произведём обучение нейронной сети. На выходе нейронной сети находится вероятность p , показывающая степень «уверенности» нейронной сети о принадлежности прецедента к первому или второму классу [2]:

$$p = f \left(\sum_{i=1}^n x_i w_i \right),$$

где x_i – значение i -го входа нейрона, w_i – вес i -ой связи, n – число входов нейрона, f – функция активации (в данном примере используется сигмоида).

Для обеспечения селективности релейной защиты на нейросетевом классификаторе необходимо выбрать пороговое значение. Значение вероятности на выходе нейронной сети выше этого порога будет означать принадлежность режима к первому классу, вероятность ниже порога – ко второму. Проведём на той же комплексной плоскости \underline{z} изолинии, каждая из которых будет соответствовать определённой вероятности. Порог необходимо выбрать таким, чтобы соответствующая ему изолиния совпадала с истинной границей (зелёная линия). Как видно из рисунка, вне зависимости от сложности нейронной сети, при обучении на ограниченном числе прецедентов нет возможности выбрать порог так, чтобы это обеспечивало наибольшую чувствительность и при этом гарантировало

селективность. В случае слишком простой нейронной сети изолинии, расположенные близко к истинной границе практически вырождаются в линию, а в случае слишком сложной начинают излишне ориентироваться на отдельно расположенные прецеденты.

Если имеется гораздо более объёмная и соответственно информативная база прецедентов (в данном примере по 5000 для каждого класса), то появляется возможность выбрать порог так, чтобы соответствующая изолиния совпала с истинной границей, в пределах которой на комплексной плоскости отображаются внешние короткие замыкания (рис. 2).




Рис. 2. Изолинии нейронной сети (15 нейронов) при большом объёме информационной базы

Заключение

Таким образом, нейронная сеть, обученная по ограниченному, случайному количеству прецедентов, не может гарантировать селективную работу и обеспечить максимальную чувствительность. Чтобы нейронная сеть соответствовала этим требованиям необходимо иметь заведомо избыточную информационную базу, либо разработать алгоритм, который позволит генерировать такую информационную базу, в которой каждый отдельно взятый прецедент был бы максимально информативен.

СПИСОК ЛИТЕРАТУРЫ

1. Haykin, S. Neural Networks: A Comprehensive Foundation. 1998. - 842 с.

Авторы:

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

Маслов Александр Николаевич, ООО «Релематика»/ЧГУ им. И.Н. Ульянова, инженер-исследователь, e-mail maslov.a.n@list.ru.

Николаев Кирилл Петрович, ООО «Релематика»/ЧГУ им. И.Н. Ульянова, техник-исследователь, e-mail nikolaev.kirill.p@mail.ru.