



Рисунок 2 – UML – диаграмма вариантов использования

Литература

1. Прохоров, С.А. Аппроксимация плотности вероятности случайных процессов ядерными функциями и ортогональными полиномами [Текст] / Прохоров С.А., Лёзин И.А., Лёзина И.В., Соболева А.Е. Инновационные технологии в управлении, образовании, промышленности «АСТИНТЕХ-2007»: материалы Всероссийской научной конференции в 2 ч. Часть 2. / сост. И.Ю.Петрова. / Издательский дом «Астраханский университет» – Астрахань, 2007. – С. 136-139. – Библиогр.: с.139.
2. Прохоров, С.А. Аппроксимативный анализ случайных процессов. [Текст] / А.С.Прохоров. –2-е изд., перераб. и доп./СНЦ РАН, 2001. – 125с.
3. Деврой, Л. Непараметрическое оценивание плотности. L1 – подход [Текст] / Деврой Л., Дьерфи Л. Пер. с англ. – М.: Мир, 1988. – 408 с. – ISBN 5-03-000475-0.
4. Электронный ресурс <https://www.mql5.com/ru/articles/396>. Дата обращения 07.03.2016
5. Манухин А.В. Аппроксимация плотности вероятности ядерными функциями / А.В. Манухин, И.В. Лёзина // XIII Королёвские чтения: Международная молодёжная научная конференция: сборник трудов, том 2 – Самара: Издательство СГАУ, 2015. – С. 97 - ISBN 978-5-9905304-6-1.

В.В. Муравьев, И.А. Лёзин

АНАЛИЗ ЭФФЕКТИВНОСТИ АЛГОРИТМОВ ОБУЧЕНИЯ НЕЧЕТКОЙ НЕЙРОННОЙ СЕТИ ВАНГА-МЕНДЕЛЯ

(Самарский национальный исследовательский университет
имени академика С.П. Королёва)

Постановка задачи

Нейронная сеть, как правило, используется тогда, когда неизвестен точный вид связей между входами и выходами, – если бы он был известен, то связь можно было бы моделировать непосредственно. Другая существенная особенность нейронных сетей состоит в том, что нейронная сеть является универсальным аппроксиматором, т.е. способна реализовывать любую функцию при должном обучении.

Для решения задачи классификации была выбрана сеть Ванга-Менделя. Сеть Ванга-Менделя относится к классу нечетких продукционных нейронных сетей, которые обладают возможностью работы с неопределенными, неполными или неточными данными.

Основной проблемой при работе с нейронной сетью является выбор способа ее обучения. Распространенным методом является метод обратного распространения ошибки, используемый вместе с градиентными алгоритмами обучения. Недостатком градиентных методов является гарантированное нахождение локального, а не глобального минимума. Стохастические методы обучения, такие как генетический алгоритм или алгоритм имитации отжига, позволяют избежать закливания алгоритма в точке локального минимума за счет применения как детерминированного, так и случайного этапов преобразования нейронной сети [1].

Структура и функциональные особенности сети

Наиболее важным фактором, влияющим на качество решения задачи с помощью нейронных сетей, является структура нейронной сети. Так как сеть Ванга-Менделя имеет фиксированное число слоев, то основной метод влияния на структуру сети - изменение количества нейронов в слоях.

От количества нейронов в сети также зависит количество операций на одной итерации обучения. С одной стороны, уменьшение количества нейронов ведет к сокращению времени обучения сети. С другой стороны, малое количество нейронов ведет к увеличению ошибки обучения [2].

Также стоит учитывать функциональные особенности сети. Сеть Ванга-Менделя построена на основе нечеткой модели Мамдани-Заде. В модели Мамдани-Заде определены 3 вида операций – Т-норма (\otimes), S-норма (\oplus) и импликация (\rightarrow). Совокупность данных операций называется алгеброй нечеткого вывода. В данной работе рассматривались следующие алгебры, предложенные в работе [1]:



1. Алгебра Гёделя

$$\mu_A(x) \otimes \mu_B(y) = \min\{\mu_A(x), \mu_B(y)\}$$

$$\mu_{A \rightarrow B}(x, y) = \begin{cases} 1, \mu_A(x) \leq \mu_B(y) \\ \mu_B(y), \mu_A(x) > \mu_B(y) \end{cases}$$

$$\mu_A(x) \oplus \mu_B(y) = \max\{\mu_A(x), \mu_B(y)\}$$

2. Алгебра Гогена

$$\mu_A(x) \otimes \mu_B(y) = \mu_A(x)\mu_B(y)$$

$$\mu_{A \rightarrow B}(x, y) = \begin{cases} 1, \mu_A(x) \leq \mu_B(y) \\ \mu_B(y) / \mu_A(x), \mu_A(x) > \mu_B(y) \end{cases}$$

$$\mu_A(x) \oplus \mu_B(y) = \mu_A(x) + \mu_B(y) - \mu_A(x)\mu_B(y)$$

3. Алгебра Лукашевича

$$\mu_A(x) \otimes \mu_B(y) = \max\{0, \mu_A(x) + \mu_B(y) - 1\}$$

$$\mu_{A \rightarrow B}(x, y) = \min\{1, 1 - \mu_A(x) + \mu_B(y)\}$$

$$\mu_A(x) \oplus \mu_B(y) = \min\{1, \mu_A(x) + \mu_B(y)\}$$

Алгоритмы обучения сети

Также важным фактором, влияющим на качество решения задачи, является выбор алгоритма обучения. В рамках данной работы рассматривалось обучение сети при помощи следующих алгоритмов:

- Градиентные алгоритмы:
 1. Алгоритм наискорейшего спуска и метод обратного распространения ошибки (ОРО) [2]
 2. Метод сопряженных градиентов (АСГ) [2]
- Стохастические алгоритмы:
 1. Генетический алгоритм (ГА) [3]
 2. Алгоритм имитации отжига (АИО) [2]
 3. Алгоритм имитации роя частиц (АИРЧ) [4]
 4. Алгоритм дифференциальной эволюции (АДЭ) [5]

Экспериментальные исследования и их оценка

Как показатель качества обучения для количественной оценки разности между ожидаемым и реальным значениями на выходах нейронной сети рассчитывались суммарное среднеквадратическое отклонение (СКО) обучения, определяемое формулой

$$СКО = \sqrt{\frac{1}{V-1} \cdot \frac{1}{E} \cdot \sum_{i=1}^V \sum_{j=1}^E (y_{j,i} - d_{j,i})^2},$$

а также погрешность классификации, равная отношению количества неверно распознанных данных к общему размеру выборки

Выбранные оценки качества будем рассчитывать как на этапе обучения, так и на этапе тестирования нейронных сетей. В дальнейшем будем называть их погрешностями обучения и тестирования соответственно. Погрешность обучения показывает, насколько хорошо нейронная сеть способна накапливать информацию об обучающих выборках. Погрешность тестирования характеризует



способность сети к обобщению полученных знаний, то есть находить зависимость выходных сигналов от входных данных, не участвующих в обучении.

В качестве данных тестовых задач были взяты задачи классификации ирисов и классификации вин из репозитория UCI Калифорнийского университета [6].

Результаты

Таблица 1. СКО обучения и погрешность классификации при решении задач классификации ирисов/вин

Тип алгоритма и алгебра	СКО обучения	Погрешность классификации	Количество нейронов	Количество итераций
ОРО, Гёделя	0,159/0,164	0,033/0,014	12/39	5000/5000
ОРО, Гогена	0,168/0,006	0,033/0,000	36/39	5000/5000
ОРО, Лукашевича	0,161/0,194	0,033/0,028	12/39	1000/1000
ГА, Гёделя	0,151/0,143	0,033/0,028	36/65	1000/500
ГА, Гогена	0,136/0,025	0,033/0,000	12/117	5000/1000
ГА, Лукашевича	0,141/0,122	0,011/0,028	20/39	500/5000
АИО, Гёделя	0,139/0,191	0,033/0,049	12/39	5000/5000
АИО, Гогена	0,166/0,138	0,056/0,028	12/39	5000/5000
АИО, Лукашевича	0,362/0,278	0,333/0,063	12/39	5000/5000
АИРЧ, Гёделя	0,115/0,174	0,011/0,042	12/39	50/50
АИРЧ, Гогена	0,094/0,098	0,000/0,007	12/39	50/50
АИРЧ, Лукашевича	0,239/0,282	0,033/0,113	12/39	50/50
АДЭ, Гёделя	0,354/0,403	0,167/0,190	12/39	100/500
АДЭ, Гогена	0,324/0,273	0,167/0,092	36/39	100/100
АДЭ, Лукашевича	0,447/0,271	0,578/0,120	12/39	1000/1000
АСГ, Гёделя	0,363/0,410	0,289/0,239	12/39	1/5
АСГ, Гогена	0,346/0,379	0,311/0,317	12/39	5/1
АСГ, Лукашевича	0,355/0,410	0,244/0,169	12/39	5/50

В ходе исследований было выяснено, что ОРО, ГА, АИО и АИРЧ качественно обучают сеть нечеткую сеть Ванга-Менделя. С другой стороны, алгоритмы АДЭ и АСГ не показали хороших результатов обучения данной сети.

Относительное сравнение результатов различных алгоритмов показало:

1. ОРО – в основном требует большое количество итераций обучения - часто 5000 и более (ГА зачастую хватает и 500 итераций).
2. ГА требует большее количество нейронов по сравнению с применением остальных алгоритмов.
3. АИО показывает практически полную неспособность обучать сеть при использовании в качестве алгебры нечеткой логики алгебры Лукашевича.



4. АИРЧ может обучать сеть только в «оффлайн»-режиме, в отличие от остальных алгоритмов, к тому же требует метаоптимизация его параметров требует много больше ресурсов, чем для других алгоритмов.
5. Проблемным место АДЭ является его кроссовер, не пригодный для обучения данного типа сетей.
6. АСГ требует решения подзадачи нахождения параметра, минимизирующего функцию. Для нечеткой сети решение данной задачи слишком нетривиально в силу нелинейности и сложности итоговой функции выхода сети.

Литература

1 Лёзин, И.А. Исследование качества решения задачи классификации нейронными нечёткими продукционными сетями на основе модели вывода Мамдани–Заде [Текст]/ И.А.Лёзин, О.П.Солдатова//Вестн. Сам.гос. техн. ун-та. Сер. Физ.-мат. науки, 2014.- 2(35). – С. 136–148.

2 Осовский, С. Нейронные сети для обработки информации [Текст]/ С. Осовский.: Пер. с пол. Рудинского И.Д. – М.: Финансы и статистика, 2002. – 344 с.: ил.

3 Лёзин И.А. Применение генетического алгоритма для обучения нечеткой многовыходовой нейронной сети Ванга-Менделя [Текст]/ И.А. Лёзин, В.В.Муравьев// Перспективные информационные технологии (ПИТ 2014): труды Международной научно-технической конференции / под ред. С.А. Прохорова/– Самара: Издательство Самарского научного центра РАН, 2014. – С.64 – 66.

4 Метод роя частиц [Электронный ресурс] - https://ru.wikipedia.org/wiki/%D0%9C%D0%B5%D1%82%D0%BE%D0%B4_%D1%80%D0%BE%D1%8F_%D1%87%D0%B0%D1%81%D1%82%D0%B8%D1%86

5 Дифференциальная эволюция [Электронный ресурс] - https://ru.wikipedia.org/wiki/%D0%94%D0%B8%D1%84%D1%84%D0%B5%D1%80%D0%B5%D0%BD%D1%86%D0%B8%D0%B0%D0%BB%D1%8C%D0%BD%D0%B0%D1%8F_%D1%8D%D0%B2%D0%BE%D0%BB%D1%8E%D1%86%D0%B8%D1%8F

6 UCI Machine Learning Repository [Электронный ресурс] - <http://archive.ics.uci.edu/ml/>



А.В. Никулина¹, П.В. Трешников², Л.С. Зеленко¹

РАЗРАБОТКА ПОДСИСТЕМЫ АВТОМАТИЗИРОВАННОГО ТЕСТИРОВАНИЯ УЧЕТА НАРАБОТКИ ГИДРОАГРЕГАТА НА ОСНОВЕ МОДЕЛИ ЕГО РАБОТЫ

(Самарский национальный исследовательский университет
имени академика С.П. Королёва,
²ООО «Гидроавтоматика»)

Основной целью создания систем учета наработки является предотвращение аварийных ситуаций. Для этого необходимо собирать и обрабатывать данные о техническом состоянии оборудования, которые позволили бы прогнозировать отказы и своевременно выполнять профилактические мероприятия.

В соответствии с оперативным указанием ОАО «Федеральная гидрогенерирующая компания – РусГидро» ОУ-08-2014 «Об организации автоматической регистрации технологических показателей режима работы гидроагрегатов» (далее по тексту ОУ-08) на всех ГЭС должны быть введены системы учета наработки её гидроагрегатов (ГА), обеспечивающие непрерывный контроль и регистрацию следующих параметров наработки:

- количество пусков и останов ГА;
- длительность суммарного времени работы ГА в каждом режиме работы и зоне работы;
- количество вхождений в каждый режим работы и зону работы.

Для повышения эффективности оперативного управления, увеличения производительности труда персонала, контроля ресурса оборудования и приведения эксплуатации гидротурбин в соответствие с ОУ-08 в ООО «Гидроавтоматика» разрабатывается программное обеспечение «Универсальная форма наработки ГА», которое позволит автоматически обрабатывать технологические показатели режимов работы гидроагрегатов. Данная система выполнена в виде самостоятельного web-приложения, которое поддерживает выполнение следующих функций [1]:

- 1 при наличии систем автоматизированного управления (САУ) ГА импорт режимов работы и параметров наработки ГА из САУ ГА.
- 2 при отсутствии САУ ГА:
 - определение режимов работы по алгоритмам на основе параметров, регистрируемых различными системами АСУТП, при этом алгоритмы определения режимов/зон согласовываются индивидуально для каждой ГЭС;
 - ручной ввод параметров наработки при отсутствии автоматизированного потока данных – регистрация пусков и остановов, переходов между режимами и зонами работы;