

На основании вышеописанного гибридного евклидового расстояния производится разделение изображения на сегменты, каждый из которых после проверяется на наличие значимых объектов по карте значимости, полученной параллельно (так как задачи сегментации и получения карты значимости независимы, их исполнение может быть произведено параллельно), после чего из изображения извлекается набор значимых сегментов, каждый из которых может быть искомым объектом.

Дальнейшее действие зависит от стратегии реагирования: в случае, если за видеопотоками каждого агента следит оператор, то подзадачу распознавания решать не нужно; достаточно сконцентрировать внимание оператора на наиболее плотном кластере значимых сегментов, для чего можно использовать тактику центрирования камеры на средневзвешенной точке изображения после каждой обработки изображения:

$$\bar{X} = \frac{\sum_{i=1}^N X_i S_i}{\sum_{i=1}^N S_i}, \quad (5)$$

где N – количество значимых сегментов, X_i – координаты центра масс каждого из сегментов, а S_i – площадь каждого из значимых сегментов. В этом случае при центрировании на группе значимых сегментов при отсутствии иных кластеров таких сегментов на последующих изображениях агент впадает в устойчивое равновесие, посылая сигнал оператору о таком кластере, а при наличии большого числа разбросанных по изображению значимых сегментов будет медленно переводить своё внимание на большее скопление таковых сегментов.

При отсутствии оператора агенту придётся решать также вопрос распознавания значимых сегментов, что скажется на быстродействии агента. В дальнейшем планируется исследование обеих стратегий реагирования, тактик реагирования при наличии оператора и тактик распознавания при его отсутствии.

Список цитированных источников

1. Абчук, В.А. Поиск объектов / В.А. Абчук, В.Г. Суздаль. – М.: Советское радио, 1977.
2. Ramík, Dominik Maximilián. A machine learning based intelligent vision system for autonomous object detection and recognition / Ramík, Dominik Maximilián [et al.] *Applied Intelligence* (2013): 1-18.
3. Ramík, Dominik Maximilián. Hybrid salient object extraction approach with automatic estimation of visual attention scale / Ramík, Dominik Maximilián, Christophe Sabourin, and Kurosh Madani. *Signal-Image Technology and Internet-Based Systems (SITIS), 2011 Seventh International Conference on*. IEEE, 2011.

УДК 004.8

МЕТОДИКА ДИНАМИЧЕСКОЙ ИНИЦИАЛИЗАЦИИ ШАГА ОБУЧЕНИЯ В АЛГОРИТМЕ BACK PROPAGATION ERROR

Савицкий А.Ю.

Брестский государственный технический университет, г. Брест
Научный руководитель: Савицкий Ю.В., к.т.н., доцент

В работе предлагается и обосновывается методика динамической инициализации индивидуального шага обучения в алгоритме Back Propagation Error (обратного распространения ошибки), по настоящее время остающемся наиболее популярным для обучения многослойных нейронных сетей. Результаты вычислительных экспериментов демонстрируют практическую значимость и перспективность метода.

Введение

В настоящее время в мире накоплено значительное количество теоретических результатов и большой практический опыт в применении аппарата искусственных нейронных сетей для обработки информации в различных сферах. Предложен ряд высокоэффективных алгоритмов обучения (в том числе Back Propagation Error, BPE), позволяющих улучшить адаптивные свойства нейросетевых моделей. Ключевым моментом задачи проектирования нейронных систем по настоящее время остается проблема эффективного обучения нейронных сетей [1]. При этом используемые для обучения алгоритм BPE и его известные модификации обладают принципиальными недостатками, связанными с необходимостью выбора констант обучения, следствием чего являются проблемы низкой сходимости и стабильности обучения, а также проблемы локальных минимумов [1,2,3,8]. Применяемые в настоящее время для обучения нейронных сетей более совершенные методы оптимизации (сопряженных градиентов [4, 5], Ньютона [5, 7], Левенберга-Марквардта [5,9]), хотя и позволяют значительно улучшить процесс сходимости алгоритма, также обладают существенными недостатками, сильно ограничивающими их эффективное применение в практических задачах. Наиболее характерными из этих недостатков являются большая вычислительная сложность итерации обучения, высокая чувствительность алгоритма к погрешностям вычислений, низкая сходимость при большом удалении целевой функции обучения от точки минимума [5]. Все это является весьма серьезным ограничением для использования нейросетевых моделей в практических задачах. Данная работа является продолжением комплекса научных исследований по оптимизации работы алгоритма BPE в контексте решения задачи выбора значения шага обучения. Главной целью своей работы автор считает снижение степени неопределенности значения шага обучения в алгоритме BPE при решении практических задач организации нейросетевых моделей.

1. Методика инициализации шага обучения

Главная идея данной работы заключается в применении в алгоритме BPE метода индивидуальной случайной инициализации шага обучения на каждой обучающей итерации. Предпосылки и суть идеи сводятся к следующему:

1. В алгоритме BPE и во всех его наиболее распространенных модификациях традиционно используется стратегия инициализации каждого весового коэффициента нейронов случайным числом, равномерно распределенным на некотором диапазоне, границы которого задаются эмпирически. Необходимость такого подхода обусловлена неопределенностью информации о начальных значениях весовых коэффициентов. При этом результат обучения существенно зависит от удачной инициализации сети; в ряде случаев, для достижения приемлемой ошибки обучения приходится неоднократно повторять данный процесс.

2. Проблему неопределенности шага обучения в алгоритме BPE предлагается решить на базе аналогичного подхода. Это означает, что на каждой итерации алгоритма для каждого весового коэффициента значение шага определяется методом вызова функции, генерирующей случайное равномерно распределенное число. Нижняя и верхняя границы инициализации определяются эмпирически как минимальное и максимальное приемлемые значения шага. Предпосылкой подхода является то, что при неудачном выборе значения глобального шага существует вероятность попадания целевой функции обучения в локальный минимум (что часто и имеет место в реальных задачах обучения). С другой стороны, случайное варьирование шага для каждого весового коэффициента в допустимом диапазоне значений на каждой итерации алгоритма уменьшает такую вероятность, что должно обеспечивать более высокую сходимость алгоритма к приемлемой ошибке обучения.

2. Результаты экспериментов

Были проведены две группы экспериментов. Многослойная нейронная сеть архитектуры 7-5-1 – 7 входных нейронов, 5 скрытых нейроэлементов с сигмоидной функцией активации и 1 нейрон линейного типа – обучена прогнозированию хаотического процесса Энона [6] по методу скользящего окна (взято 510 элементов ряда) [6]. Количество выполненных итераций обучения $NIT=10000$.

1. Шаг обучения – случайный, выбираемый по вышеуказанной методике, с диапазоном инициализации $[0,01; 0,001]$. Результаты для 20 попыток обучения: средняя ошибка обучения (средний квадрат ошибки) $MSE = 7,53E-06$; среднеквадратичное отклонение ошибки обучения $SD = 5,08E-04$.

2. Шаг обучения – глобальный детерминированный, равный 0,045 (середина диапазона инициализации шага для предыдущего эксперимента). Результаты для 20 попыток обучения: $MSE = 2,34E-05$; $SD = 7,97E-03$.

Таким образом, за счет применения методики случайной инициализации шага в алгоритме BPE ошибку обучения удалось сократить в 3,1 раза, при этом еще более существенно уменьшается параметр SD . Последнее говорит о значительном повышении стабильности процесса сходимости алгоритма BPE для вышеуказанного числа экспериментов обучения. Аналогичные результаты были получены и в других задачах обучения. В частности, при обучении нейронной сети архитектуры 5-4-1 на прогнозирование временных рядов, синтезированных на базе суперпозиции периодических функций, ошибка обучения сократилась в среднем в 1,74 раза, при одновременном уменьшении параметра SD – почти в 2 раза (диапазон инициализации шага $[0; 0,1]$, размер глобального шага 0,05, количество попыток обучения 30).

3. Заключение

По мнению автора, полученные результаты имеют практическую значимость, поскольку, во-первых, увеличивают скорость и стабильность процесса сходимости алгоритма BPE, во-вторых, создают предпосылки для эффективной параллелизации процесса обучения на многокомпонентных вычислительных архитектурах – предложенная методика динамической инициализации шага обучения не зависит от обучающего множества, промежуточных параметров обучения нейронной сети и других факторов, влияющих на эффективность процесса параллелизации. В качестве объективных недостатков метода можно отметить некоторые незначительные осцилляции ошибки при переходе от итерации к итерации, которые в целом несущественно влияют на конечный результат обучения нейронной сети.

Список цитированных источников

1. Hertz, J. Introduction to the Theory of Neural Computation / J. Hertz, A. Krogh, R. Palmer; Addison Wesley Publishing Company. – 1991. – 327 p.
2. Golovko, Vladimir. New Approach of the Recurrent Neural Network Training / Vladimir Golovko, Yury Savitsky // Proc. of the Int. Conf. on Neural Networks and Artificial Intelligence ICNNAI'99, 12-15 october 1999. – Brest, Belarus, 1999. – P. 32-35.
3. Rumelhart, D.E. Learning Representations by Backpropagating Errors / D.E. Rumelhart, G.E. Hinton, and R.J. Williams // Nature. 1986. – Vol. 323. – P. 533-536.
4. Johansson, E.M. Backpropagation Learning for Multilayer Feedforward Neural Networks Using the Conjugate Gradient Method / E.M. Johansson, F.U. DOWLA, and D.M. Goodman // Int. J. Neural Systems. – 1992. – Vol. 2. – № 4. – P. 291-302.
5. Поляк, Б.Т. Введение в оптимизацию. – М: Наука, 1983. – 384 с.
6. Golovko, V. Neural Networks for Signal Processing in Measurement Analysis and Industrial Applications: the Case of Chaotic Signal Processing / V. Golovko, Y. Savitsky, N. Maniakov // chapter of NATO book «Neural networks for instrumentation, measurement and related industrial applications». – Amsterdam: IOS Press, 2003. – P. 119-143.

7. Osowski, S. Fast Second-Order Learning Algorithm for Feedforward Multilayer Neural Networks and its Applications / S. Osowski, P. Wojarczak, and M. Stodolski // Neural Networks. – 1996. – Vol. 9. – № 9. – P. 1583-1596.

8. Осовский, С. Нейронные сети для обработки информации / С. Осовский; пер. с польского И.Д. Рудинского. – М.: Финансы и статистика, 2002. – 334 с.

9. Martin, T.H. Training Feedforward Network with Marquardt Algorithm / T.H. Martin and B.M. Mohammad // IEEE Trans. Neural Networks. – 1996. – Vol. 5. Nov. – P. 959-96.

УДК 519.863

ИСПОЛЬЗОВАНИЕ МЕТОДА КОЛОНИИ МУРАВЬЕВ ДЛЯ РЕШЕНИЯ ЗАДАЧ НАХОЖДЕНИЯ ПУТЕЙ С ЗАДАНЫМИ СВОЙСТВАМИ

Степин Ю.Г., Гайдаш О.В., Заман И.Э.

*Гродненский государственный университет им. Янки Купалы, г. Гродно
Научный руководитель: Степин Ю.Г.*

В последнее время активно развивается научное направление, объединяющее математические методы, основанные на принципах природных механизмов принятия решений (Natural Computing – «Природные вычисления»). Одним из методов данного направления является муравьиный алгоритм, или оптимизация по принципу муравьиной колонии, который впервые был предложен М. Дориго (Marco Dorigo) [1].

Муравьиный алгоритм интересен тем, что его можно использовать для решения не только статичных, но и динамических проблем. С помощью данного алгоритма в настоящее время решаются такие задачи, как: задача о коммивояжере [2], задача о рюкзаке, создание игрока-компьютера в игре Pac-Man, создание системы принятия экономических решений в автоматной модели производства, задача календарного планирования, задача реализации криптоанализа шифров перестановок, в сфере логистики задача на составление плана движения транспорта [3].

В данной статье рассматривается применение муравьиного алгоритма для решения задачи нахождения путей с заданными свойствами и с набором дополнительных ограничений в виде ресурсов. В нашем случае рассматривается движение автомобиля с ограничениями на топливо из одного города в другой.

Любой муравьиный алгоритм, независимо от модификаций, можно представить в виде последовательности действий.

1. Создание муравьев.

Количество муравьев и вершины, в которые они помещаются, зависит от ограничений, определяемых условиями задачи. На этом же этапе задается начальный уровень феромона.

2. Поиск решений.

Вероятность перехода из вершины i в вершину j определяется по формуле (1).

$$P_{ij}(t) = \frac{\tau_{ij}(t)^\alpha \left(\frac{1}{d_{ij}}\right)^\beta}{\sum \tau_{ij}(t)^\alpha \left(\frac{1}{d_{ij}}\right)^\beta}, \quad (1)$$

где $\tau_{ij}(t)$ – уровень феромона (глобальный показатель), d_{ij} – эвристическое расстояние (локальный показатель), α, β – константные параметры, определяющие значимость глобального и локального показателей.