И. В. МИЛОСЕРДОВ, Д. И. МИЛОСЕРДОВ
Санкт–Петербургский институт информатики и автоматизации Российской Академии наук (СПИИРАН),
Санкт-Петербург

РАЗРАБОТКА МЕХАНИЗМОВ ОБЕСПЕЧЕНИЯ УСТОЙЧИВОСТИ В НЕЙРОСЕТЕВЫХ СИСТЕМАХ ПРОГНОЗИРОВАНИЯ

Рассмотрена проблема обеспечения устойчивого функционирования систем прогнозирования временных рядов, в основу которых положены потоковые рекуррентные нейронные сети с управляемыми элементами. Выведены механизмы, необходимые и достаточные для ее поддержания, предполагающие соблюдение баланса истории обучения и модификацию правила обучения синапсов, с целью установления равновесия между положительным и отрицательным потенциалом. Приводятся результаты экспериментов по оценке точности прогнозирования.

Введение. Для прогнозирования временных рядов применяются как нейронные сети прямого распространения [1], так и рекуррентные нейронные сети (РНС) [2, 3]. Известны гибридные решения, сочетающие различные нейросетевые архитектуры или комбинирующие нейросетевые и традиционные методы [4]. РНС позволяют производить более глубокую обработку информации, располагают механизмами ассоциативного вызова информации из своей памяти. К ним относятся и РНС с управляемыми элементами [5]. В отличие от аналогов, эти РНС могут наделяться различными пространственно-временными структурами, что повышает их потенциал для прогнозирования временных рядов.

В то же время, несмотря на известные преимущества, фундаментальный вопрос устойчивости функционирования нейронных сетей остается во многом не исследованным. Процесс обучения нейронной сети является итерационным, при этом сама сеть представляет собой динамическую систему с обратной связью. Архитектуры и методы обучения нейронных сетей достаточно разнообразны, что затрудняет синтезирование универсальных алгоритмов анализа устойчивости. В последнее время достаточно много работ посвящено освещению именно этого вопроса. В [6] рассматривается модель искусственной нейронной сети Хопфилда с немонотонными нелинейными связями. В [7] представлен метод анализа устойчивости систем обратной связи с нейросетевыми контроллерами. Для нейронных сетей Хопфилда в [8] получен критерий устойчивости Миттаг–Леффлера. Инерциальные нейронные сети исследованы в [9, 10]. Так, достаточные условия глобальной асимптотической устойчивости получены в [9], а условия экспоненциальной устойчивости в смысле Лагранжа в [10]. Достаточные условия устойчивости реакционно-диффузионных сетей Хопфилда рассмотрены в [11].

Доклад посвящен механизмам обеспечения устойчивости нейросетевых систем прогнозирования временных рядов, в основу которых положены РНС с управляемыми элементами. Эти системы применялись в [12, 13] и продемонстрировали преимущество над известными решениями, однако в силу отсутствия механизмов контроля устойчивости функционирования в работе таких систем требовалось участие оператора.

Задачей исследования является разработка механизмов обеспечения устойчивости РНС с управляемыми элементами и оценка их эффективности при осуществлении нейросетевого прогнозирования.

1. Архитектура программной системы нейросетевого прогнозирования. Архитектура программной системы, реализующей метод нейросетевого прогнозирования временных рядов, показана на рис. 1. Ее особенность в том, что в ее состав входят две идентичные двухслойные РНС с управляемыми элементами. Согласно методу, временные ряды преобразуются в последовательности совокупностей единичных образов (СЕО), за что отвечает блок предобработки.

Затем СЕО поступают в первую РНС и продвигаются вдоль слоев от входа к выходу, в результате чего на синапсах первой РНС формируется пространственно-временная модель. Когда необходимо получить прогноз, по команде с блока управления состояние первой РНС копируется во вторую РНС. Пока первая РНС продолжает обучаться, на второй РНС в параллельном режиме запускается обработка скопированных СЕО. Внутреннее время второй РНС многократно ускоряется, а также усиливается ассоциативный вызов сигналов в направлении входа. При этом на слоях второй РНС формируются новые СЕО, несущие прогнозные значения. После снятия СЕО с выхода второй РНС они раскодируются в блоке постобработки. Функции блока управления реализованы в модулях чтения-записи параметров, кнопочных панелях и модулях визуализации состояний слоев РНС.

Рис. 1. Архитектура программной системы нейросетевого прогнозирования

2. Механизмы обеспечения устойчивости

2.1. Критерий устойчивости. Под устойчивостью нейросетевой системы прогнозирования временных рядов будем понимать такое состояние входящих в ее состав РНС с управляемыми элементами, при котором суммарный вес $w_{sum}(t)$ всех ее синапсов находится в пределе $[-W, +W]$, где W – некоторый положительный коэффициент:

$$w_{sum}(t) = \Sigma_{i=1}^{N} \Sigma_{j=1}^{N} w_{ij}(t) \in [-W, +W]. \quad (1)$$

Здесь веса $w_{ij}(t)$ синапсов зависят от весовых коэффициентов $k_{ij}(t)$, определяющих проводимость синапсов РНС. В свою очередь, $k_{ij}(t)$ определяется выражением

$$k_{ij}(t)=(1+\exp(-\gamma\cdot g_{ij}(t)))/(1+\exp(-\gamma\cdot g_{ij}(t)))=\text{th}(\gamma\cdot g_{ij}(t)/2), \quad (2)$$

$$g_{ij}(t)=g_{ij}(t-\Delta t)+ \Delta g_{ij}(t), \quad (3)$$

где: $g_{ij}(t)$, $g_{ij}(t-\Delta t)$ – предыстория на моменты времени t и Δt соответственно; $g_{ij}(0)=0$; γ – некоторый положительный коэффициент. Величина $\Delta g_{ij}(t)$ определяется в зависимости от состояний i-го и j-го нейронов. Если i-й нейрон излучил сигнал и после этого возбудился j-й нейрон, то $\Delta g_{ij}(t)$ – положительная величина g^+. Если возбуждение j-го нейрона произошло без сигнала i-м нейрона, то $\Delta g_{ij}(t)$ отрицательно (g^-). В остальных случаях $\Delta g_{ij}(t)=0$.

2.2. Механизм контроля баланса истории обучения. Из уравнений (1) – (3) видно, что стабильность РНС зависит в первую очередь от величин $g_{ij}(t)$, на основе которых рассчитываются весовые коэффициенты. На каждом шаге функционирования РНС, согласно правилу обучения, имеется определенное количество синапсов, для которых $\Delta g_{ij}(t) = g^+$, и синапсов, для которых $\Delta g_{ij}(t) = g^-$. Первым условием устойчивости является соблюдение баланса суммарной истории обучения. Для этого введем уравнение баланса:

$$S^+(t)\cdot g^+(t) – S^-(t)\cdot g^-(t) = V, \quad (4)$$

где: V – некоторая постоянная величина (например, 0); $S^+(t)$ и $S^-(t)$ – количества синапсов, для которых $\Delta g_{ij}(t) = g^+(t)$ и $\Delta g_{ij}(t) = g^-(t)$ соответственно.

Далее синапсы, веса которых < 0, условно будем называть «тормозящими», а синапсы с положительным весом – «возбуждающими».

2.3. Модифицированное правило обучения РНС. Зависимость $k_{ij}(t)$ от $g_{ij}(t)$ нелинейная, ввиду чего баланс суммарной истории обучения недостаточен для обеспечения устойчивости РНС. Дополнительным требованием является баланс «возбуждающего» и «тормозящего» потенциала синапсов. Иными словами, на каждом такте обучения РНС необходимо, чтобы количество синапсов, вес которых в соответствии с правилом обучения снизился, равнялось количеству синапсов с возросшим весом. В то же время, текущее правило обучения не отвечает этому требованию, поскольку количество «возбуждающих» и «тормозящих» синапсов зависит от соотношения возбужденных и ожидающих нейронов, которое может меняться с течением времени. Одним из путей уравнивания количества «возбуждающих» и «тормозящих» синапсов является модификация правила обучения. По сравнению с изначальным правилом, предлагается уменьшать вес *ij*-го синапса, если *i*-й нейрон находился в состоянии рефракторности, а в следующий момент времени возбудился *j*-й нейрон. При этом количество тактов рефракторности нейронов подбирается таким образом, чтобы количество возбужденных нейронов в слое равнялось количеству активных.

Рис. 2. Состояние первого слоя второго РНС при прогнозировании транспортных потоков

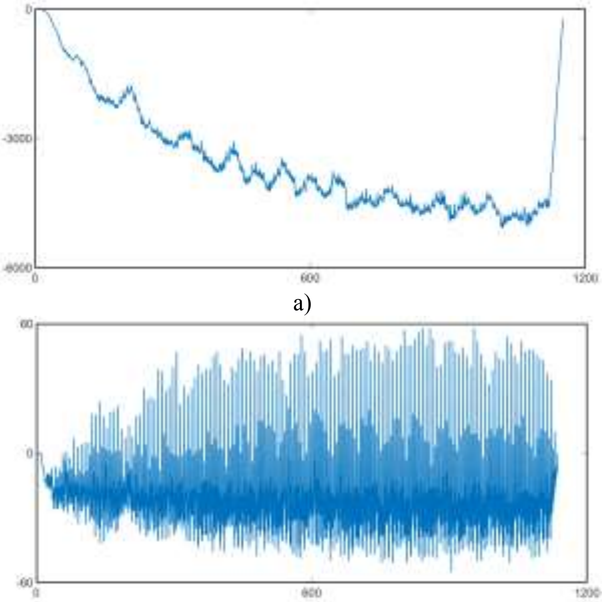

б)

Рис. 3. Динамика параметров суммарного весового коэффициента при обучении РНС без (а) и с (б) использованием механизмов контроля устойчивости

3. Эксперименты. Предложенные решения исследовались на примере прогнозирования городского дорожного трафика в г. Санкт-Петербург. Для этого была сконфигурирована РНС размером 5×6 логических полей, каждое из которых имело размер 4×8 нейронов (рис. 2). Глубина прогнозов составляла 12 дней, а горизонт – 2 дня при интервале 3 часа.

Первая серия экспериментов проводилась без привлечения механизмов контроля устойчивости. На рис. 3 показана динамика суммарного веса РНС. По горизонтальной оси графиков отложены такты работы РНС, по вертикальной – значения соответствующих параметров. Из графиков видно, что суммарный весовой коэффициент заметно уходит в отрицательную область значений. Это обуславливается превалированием количества «тормозящих» синапсов над «возбуждающими» (на рис. 2 в среднем в одном логическом поле возбуждены лишь 4 из 32 нейронов).

Вторая серия проводилась с привлечением механизмов контроля устойчивости. Рис. 3*б* демонстрирует аналогичный график для этой ситуации. Видно, что суммарный вес находится на постоянном уровне, а колебания суммарного веса не выходят за пределы -60...+60 (против -5000...0 в предыдущей серии).

Согласно результатам экспериментов, механизмы контроля устойчивости позволили снизить ошибку MAE на 13.8 %, MAPE – на 10.5 %, RMSE – на 10.0 %, что свидетельствует об эффективности предложенных решений.

Заключение. Рассматриваемая РНС с управляемыми элементами обладает более гибкой структурой за счет расширения возможностей по маршрутизации сигналов и взаимосвязей элементов. Наращивание управляемости сети обуславливает необходимость слежения за ее устойчивостью в процессе обучения, для чего были разработаны критерий устойчивости и механизмы ее контроля. На числовых примерах, отображающих суммарный вес нейронной сети во время обучения, показано, что предложенные механизмы отвечают необходимым требованиям.

ЛИТЕРАТУРА

1. Hyndman R.J., Athanasopoulos G. Forecasting: principles and practice, 2nd ed. *Melbourne, Australia*. 2018.
2. Polson N.G., Sokolov V.O. Deep learning for short-term traffic flow prediction. *Transportation research Part C 79*. 2017. P. 1–17. http://dx.doi.org/10.1016/j.trc.2017.02.024
3. Fernandez-Navarro M., Cruz M.A., Gutierrez P.A., Castano A., Hervas-Martınez C. Time series forecasting by recurrent product unit neural networks. *Neural Comput & Applic.* 2018. P. 29:779–791. https://doi.org/10.1007/s00521-016-2494-2
4. Goudarzi S., Kama M.N., Anisi M.H., Soleymani S.A., Doctor F. Self-organizing traffic flow prediction with an optimized deep belief network for Internet of vehicles. *Sensors*. 2018. Vol.18. P. 3459. doi:10.3390/s18103459

5. Osipov V., Osipova M. Space–time signal binding in recurrent neural networks with controlled elements. *Neurocomputing*. 2018. Vol. 308. P. 194–204. https://doi.org/10.1016/j.neucom.2018.05.009
6. Wang H., Wei G., Wen S., Huang T. Generalized norm for existence, uniqueness and stability of Hopfield neural networks with discrete and distributed delays. *Comparative Study Neural Netw.* 2020. P. 667–675.
7. Yin H., Seiler P., Arcak M. Stability Analysis using Quadratic Constraints for Systems with Neural Network Controllers. *Electrical Engineering and Systems Science*. 2020.
8. Wang F., Liu X., Tang M., Chen L. Further results on stability and synchronization of fractional-order Hopfield neural networks. *Neurocomputing*. 2019. Vol. 346. P. 12–19. https://doi.org/10.1016/j.neucom.2018.08.089
9. Cui N., Jiang H., Hu C., Abdurahman A. Global asymptotic and robust stability of inertial neural networks with proportional delays. *Neurocomputing*. 2018. Vol. 272. P. 326–333. https://doi.org/10.1016/j.neucom.2017.07.001
10. Lu S., Gao Y. Exponential stability in Lagrange sense for inertial neural networks with time-varying delays. *Neurocomputing.* 2019. Vol. 333. P. 41–52. https://doi.org/10.1016/j.neucom.2018.12.063
11. Liu P., Cao G. Employing the Friedrichs' inequality to ensure global exponential stability of delayed reaction-diffusion neural networks with nonlinear boundary conditions. *Neurocomputing.* 2020. Vol. 383. P. 81–94. https://doi.org/10.1016/j.neucom.2019.11.091
12. Osipov V., Miloserdov D. Neural network forecasting of traffic congestion. *Digital Transformation and Global Society. Springer, Cham*, 2020. Vol. 1038. https://doi.org/10.1007/978-3-030-37858-5_20
13. Osipov V., Zhukova N., Miloserdov D. Neural Network Associative Forecasting of Demand for Goods. *Experimental Economics and Machine Learning*. *Perm*, 2019. Vol. 2479.

I.V. Miloserdov, D.I. Miloserdov (St. Petersburg Institute for Informatics and Automation of the Russian Academy of Sciences (SPIIRAS), St. Petersburg)

Development of Mechanisms for Stability Ensuring in Neural Network Forecasting Systems

The problem of ensuring the stable functioning of time series forecasting systems based on stream recurrent neural networks with controlled elements is considered. The mechanisms necessary and sufficient for its maintenance are derived, assuming the balance of the learning history and modification of the synapses learning rule, in order to establish a balance between positive and negative potential. The results of experiments to assess the accuracy of forecasting are presented.