

УДК 681.5.09; 004.052.44; 004.032.26

С. Ван, В.Л. Елисеев

Методика повышения качества нейросетевого моделирования динамических объектов

Рассматривается задача нейросетевого моделирования нелинейных динамических объектов с помощью рекуррентных нейронных сетей. Предлагается подход по улучшению точности моделирования с помощью статической нейронной сети типа «многослойный перцептрон», обрабатывающей корреляционные зависимости динамического процесса и аппроксимирующей ошибку моделирования. Сформулирована методика синтеза и применения корреляционной нейросетевой модели CCF-MLP, обеспечивающей улучшение качества моделирования обычной рекуррентной нейронной сети. Проведены имитационные эксперименты с нейросетевой рекуррентной сетью типа GRU, моделирующей поведение нелинейного динамического объекта, а также GRU с предложенной моделью CCF-MLP. Подтверждено улучшение качества моделирования (RMSE, MAPE) при применении CCF-MLP как в случае наличия, так и отсутствия помехи в наблюдаемых данных. Практическая применимость предложенного метода проверена на реальной системе контроля уровня жидкости.

Ключевые слова: взаимная корреляционная функция, многослойный перцептрон, рекуррентная нейронная сеть, моделирование динамического объекта, нелинейный динамический объект.

DOI: 10.21293/1818-0442-2024-27-3-92-99

Одной из важнейших задач науки и техники является создание моделей объектов и систем. Решение этой задачи открывает широкие возможности по предсказанию поведения моделируемого объекта, в том числе для целей оптимального управления. Особенно сложной задачей является синтез моделей динамических объектов, т.е. таких, где наблюдаемый выход зависит не только от текущего входа, но и от входов в предыдущие моменты времени. Таким образом, динамический объект в каком-то смысле обладает памятью, которую обычно называют состоянием. В непрерывном времени динамические объекты описываются дифференциальными уравнениями, в которых состояние представлено дифференцируемой по времени величиной:

$$\begin{cases} \dot{x} = f(x, u, t), \\ y = g(x, u, t), \end{cases} \quad (1)$$

где x – состояние объекта, u – входное воздействие на объект, y – наблюдаемый выход объекта, t – время. В случае дискретного времени вместо дифференциального уравнения используется разностное:

$$\begin{cases} x_k = f(x_{k-1}, u_k, t_k), \\ y_k = g(x_k, u_k, t_k), \\ t_k = t_{k-1} + \Delta t. \end{cases} \quad (2)$$

Состояние недоступно для непосредственного наблюдения. Кроме того, состояние субъективно – оно зависит от выбора математической структуры модели. Синтез моделей аналитическими методами в общем случае является достаточно трудоёмким процессом, поскольку требует задания в явном виде математической структуры модели и оценки её параметров. Разработка общих методик синтеза моделей для нелинейных объектов вряд ли возможна, хотя для распространенных частных случаев существуют разработанные подходы [1]. По этой причине нелинейные динамические объекты исследуются с

целью построения модели только в случае специальных требований к качеству моделирования [2].

Одними из современных инструментов непараметрического моделирования являются искусственные нейронные сети (ИНС). К неоспоримым достоинствам ИНС относится возможность синтеза модели по данным наблюдения за моделируемым объектом. Нейросетевое моделирование может осуществляться только в дискретном времени.

Рассматривая задачу нейросетевого моделирования динамических объектов, следует выделить два подхода:

- регрессионные или предсказывающие модели:

$$\tilde{y}_k = M_y(y_{k-1}, y_{k-2}, \dots, u_k);$$

- автономные или поведенческие модели:

$$\tilde{y}_k = M_y(\tilde{y}_{k-1}, u_k).$$

Регрессионные нейросетевые модели не имеют обратных связей, не хранят внутреннее состояние, но при этом обеспечивают очень высокую точность предсказания наблюдаемых выходов объекта. К недостаткам таких моделей следует отнести невозможность работы без самого объекта, относительно текущего наблюдаемого выхода которого и строится предсказание.

Автономные модели могут быть реализованы с помощью рекуррентных ИНС (Recurrent Neural Networks, RNN), и они не требуют наличия объекта для моделирования его поведения.

$$\tilde{y}_k = \text{RNN}(\tilde{y}_{k-1}, u_k). \quad (3)$$

Современными представителями рекуррентных ИНС являются сети GRU и LSTM. Отметим, что такие модели не всегда обеспечивают необходимую точность моделирования, особенно при широком спектре частот в моделируемых процессах. Повышение точности моделей типа GRU и LSTM сопряжено с увеличением количества ячеек, что повышает вычислительную сложность обучения таких моделей.

Рассмотрим подход, позволяющий увеличить точность автономной нейросетевой модели с архитектурой GRU за счёт применения взаимной корреляционной функции (ВКФ) и многослойного перцептрона (МП).

Улучшение способности нейронных сетей моделировать динамические объекты является важным и перспективным исследованием. Традиционные методы синтеза часто полагаются на точные математические модели, такие как дифференциальные и разностные уравнения, но эти модели часто ограничены сложностью и нелинейными характеристиками системы. В последние годы нейронные сети как мощный инструмент аппроксимации функций широко используются при моделировании динамических объектов благодаря своей адаптивности и способности к обучению [3, 4].

Во-первых, преимущество нейросетевого моделирования заключается в его адаптивности. Для набора наблюдений нейронная сеть может найти оптимальную конфигурацию весов, при которой взаимосвязь между входными и выходными данными будет максимально приближена к истинному динамическому поведению. Данное свойство используется в практических приложениях, поскольку нейронные сети могут аппроксимировать динамические зависимости, обычно описываемые дифференциальными и разностными уравнениями, не требуя при этом явных аналитических решений [5]. Это позволяет нейронным сетям описывать процессы и давать достаточно точные предсказания даже в отсутствие известных физических моделей.

Применение глубоких нейронных сетей, особенно рекуррентных нейронных сетей, позволяет адаптироваться к различным сложным закономерностям временных рядов, включая периодичность, тренд и шум и т.д., что очень важно для моделирования сложного поведения многих реальных систем [6].

Известные ранее недостатки рекуррентных нейронных сетей, обусловленные эффектами исчезающих и взрывающихся градиентов при обучении на длинных временных рядах, были эффективно преодолены в современных архитектурах LSTM и GRU. Эффективность рекуррентных нейронных сетей при работе с временными рядами позволяет применять их для моделирования нелинейных процессов химических реакций, таких как рН нейтрализация [7].

Во-вторых, многие инженерные приложения требуют построения моделей как часть проектирования системы управления [8]. Это связано с тем, что адаптивный регулятор, построенный на основе модели идентификации системы, обладает большей робастностью при наличии неизвестных параметров модели и внешних возмущений.

Однако применение методов моделирования нелинейных динамических объектов сталкивается со многими проблемами. Объём обучающих данных и их свойства определяют способность модели к обобщению. Если в наборе данных отсутствуют

ключевые характеристики, такие как рабочее распределение амплитуд и характерные частоты изменения сигнала, либо если присутствует значительная по интенсивности случайная помеха, то это может привести к неудовлетворительному качеству модели и низкой точности прогнозирования. Кроме того, чрезмерно сложные нейронные сети при обучении на недостаточных по объёму и вариативности обучающих данных могут не приобрести в процессе обучения обобщающую способность, плохо работая на незнакомых данных. Это особенно заметно в динамических системах, поскольку сам по себе большой объём обучающей выборки может содержать мало паттернов динамического поведения системы и не полностью описывать её динамику.

В настоящее время улучшение возможностей нейронных сетей по моделированию динамических объектов, как правило, рассматривается комплексно с точки зрения структуры сети и стратегий обучения. Например, улучшение структуры сети помогает уменьшить ошибки обобщения модели [9], а выбор различных функций потерь более устойчив к выбросам значений и шуму [10]. Также вводятся элементы конфронтации в процесс обучения, чтобы сделать модель более устойчивой к небольшим возмущениям и уменьшить ошибку распознавания при состязательной атаке [11].

Несмотря на впечатляющие результаты применения глубоких рекуррентных нейронных сетей, исследователи отмечают сложность моделирования нелинейных динамических объектов. Легко убедиться, что даже успешные, по мнению авторов статьи [12], результаты применения LSTM далеки от идеала.

Постановка задачи

Несмотря на то, что автономные модели могут быть реализованы с использованием нейронных сетей с обратной связью, предсказания модели не всегда точны. На такие модели могут влиять такие факторы, как объём и полнота обучающих данных, переобучение или недостаточное обучение, что приводит к ошибкам в результатах моделирования. Также ошибки могут возникать в случае быстрого изменения входного воздействия. Поставим задачу улучшить качество моделирования рекуррентной нейросетевой модели нелинейного динамического объекта на основе подходов по представлению динамики объекта с помощью композиции взаимной корреляционной функции (ВКФ) и ИНС.

Автономные модели функционируют параллельно и независимо от объекта (Plant), как показано на рис. 1. При работе автономных моделей всегда возникает ошибка $e_t = y_t - \tilde{y}_t$. И обычно y_t неизвестен, потому что не всегда есть эталонная модель.




Рис. 1. Автономная модель и моделируемый объект

Реальный результат объекта выражается как $y_t = e_t + \tilde{y}_t$, т.е., зная ошибку e_t или её оценку \tilde{e}_t , можно получить более точное приближение y_t . После синтеза автономной модели прогноз \tilde{e}_t , полученный путем прогнозирования ошибки прогнозирования автономной модели на основе RNN, может быть использован для дополнения результатов прогнозирования исходной модели

$$\hat{y}_t = \tilde{e}_t + \tilde{y}_t. \quad (4)$$

Вычислим взаимную корреляционную функцию (ВКФ) как характеристику входных и выходных данных рекуррентной ИНС за определенный период времени и воспользуемся этой характеристикой для прогнозирования ошибки на выходе модели RNN с помощью многослойного перцептрона (МП). Прогноз ошибки на выходе модели RNN будет использован для улучшения результатов ее прогнозирования. Будем называть модель предсказания ошибки CCF-MLP, поскольку она составлена из ВКФ (Cross-correlation function, CCF) и МП (Multi-layer perceptron, MLP). Предложенная схема улучшенной модели представлена на рис. 2.



Рис. 2. Предложенная улучшенная автономная модель и моделируемый объект

Будем сравнивать качество моделирования динамических объектов с помощью характеристик RMSE и MAPE, используемых в задачах регрессии:

$$\text{MAPE} = 100\% \times \frac{1}{N} \sum_{i=1}^N \frac{|\tilde{y}_i - y_i|}{|y_i|}, \quad (5)$$

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (\tilde{y}_i - y_i)^2}. \quad (6)$$

Методология

Существует тесная взаимосвязь между динамическим поведением системы управления и входным сигналом. Динамическое поведение – это характеристика, которая определяет реакцию системы на изменение входного сигнала, включая устойчивость, скорость отклика и установившийся выходной сигнал. Если входной сигнал с некоторой задержкой оказывает значительное влияние на объект, то корреляция между входным и выходным сигналами на времени этой задержки будет очень сильной. Взаимная корреляционная функция (ВКФ) является одним из инструментов описания этой взаимосвязи в предположении о её линейности. Последовательность ВКФ, рассчитанных в разные моменты времени, демонстрирует реакцию объекта на входной сигнал.

ВКФ является мерой оценки линейной взаимосвязи входа и выхода. В работе [13] показано, что совокупность ВКФ позволяет описать динамику нелинейных объектов. Применение ВКФ совместно с ИНС позволило решить полезные и практически важные задачи обнаружения разладки и смены рабочего режима [14, 15].

Для сигналов в непрерывном времени $u(t)$ и $y(t)$ ВКФ $r_{uy}(\tau)$ представляет степень корреляции между каждым значением входного сигнала $u(t)$ и соответствующим значением выходного сигнала $y(t + \tau)$ при временной задержке τ

$$r_{uy}(\tau) = \int_{-\infty}^{\infty} u(t)y(t + \tau)dt. \quad (7)$$

При цифровой обработке сигналов ВКФ обычно дискретизируется:

$$r_{uy}(k) = \sum_{n=0}^{N-1} u(n)y(k+n). \quad (8)$$

Поскольку ВКФ между входным и выходным сигналом содержит информацию о динамическом отклике объекта, будем аппроксимировать ошибку предсказания уточняемой рекуррентной нейросетевой модели с помощью ВКФ и МП.

Основной мотивацией использования многослойного перцептрона для прогнозирования ошибки являются его простота и возможность аппроксимации произвольных нелинейных функций. В отличие от рекуррентных нейросетей, перцептрон с ВКФ на входе может учитывать динамику системы в пределах окна расчёта ВКФ и при этом не нуждается в обратных связях. Сама ВКФ реализует локальную память, отражающую динамику моделируемого процесса.

Метод синтеза CCF-MLP

Представим изложенные идеи в форме алгоритма, обеспечивающего синтез модели CCF-MLP для предсказания прогнозируемой ошибки моделирования динамического объекта рекуррентной ИНС.

Шаг 1. Получение исходных данных. Проведём моделирование целевого процесса $y(t) = g(u(t))$ или получим набор данных вход-выход $\{u(t), y(t)\}$ при наблюдении за натурной динамической системой в дискретном времени. Это будут временные ряды входа $u(t)$ и выхода $y(t)$, где $1 \leq t \leq L$ – индекс отчёта времени, а L – длина времени моделирования или наблюдения. Обучаем соответствующую рекуррентную нейросетевую модель динамического объекта для получения набор данных вход-выход $\{u_t, \tilde{y}_t\}$, где $\tilde{y}_t = \text{RNN}(\tilde{y}_{t-1}, u_t)$. Одновременно получаем временной ряд ошибок $\{e_t\} = \{y_t - \tilde{y}_t\}$.

Шаг 2. Рассчитаем ВКФ в дискретном времени в окне шириной d по временным рядам входа u_t и выхода \tilde{y}_t нейросетевой модели динамического объекта с шагом 1 по формуле (9):

$$r_{uy}(\tau, k) = \frac{1}{d} \sum_{i=k}^{k+d-1} u_i \tilde{y}_{i+\tau} \quad (9)$$

и получим набор векторов ВКФ \mathbf{R}_{uy}^k , описывающих поведение динамической системы. Далее для обозначения номера окна, в котором рассчитывалась ВКФ, будем использовать индекс k , значения которого находятся в интервале: $1 \leq k \leq L-d+1$.

Индекс k указывает на позицию во временном ряду, в котором рассчитана данная ВКФ, а аргумент τ является смещением одного ряда относительно другого, для которого рассчитывается одно значение дискретной ВКФ. Таким образом, ВКФ в позиции k можно рассматривать, как вектор

$$\mathbf{R}_{uy}^k = (r_{uy}(-d+1, k), \dots, r_{uy}(0, k), \dots, r_{uy}(d-1, k))^T.$$

Компактно можно записать, что

$$\mathbf{R}_{uy}^k = CCF(u_k, \tilde{y}_k, d).$$

Шаг 3. Обучение многослойного перцептрона для вычисления прогнозируемого значения \tilde{e}_k делается на основе набора данных $\{\mathbf{R}_{uy}^k, \tilde{e}_{k+d-1}\}$:

$$\tilde{e}_{k+d-1} = \text{MLP}(\mathbf{R}_{uy}^k),$$

$$\sum_{k=1}^{L-d+1} (e_{k+d-1} - \tilde{e}_{k+d-1})^2 \rightarrow \min.$$

Будем соотносить рассчитанный по окну $(k, k+d-1)$ вектор ВКФ с ошибкой в позиции $k+d-1$, поскольку предсказание ошибки не должно нарушать причинно-следственную связь между сигналами.

Метод применения CCF-MLP

После того как модель прогнозирования ошибок CCF-MLP создана, она вводится для улучшения результатов прогнозирования рекуррентной ИНС. Схема показана на рис. 3 и изложена ниже по шагам.



Рис. 3. Алгоритм повышения качества нейросетевого моделирования динамических объектов

Шаг 1. Собрать временной ряд последовательных значений на входе $\mathbf{u}_k = (u_1, \dots, u_d)^T$ и на выходе $\tilde{\mathbf{y}}_k = (\tilde{y}_1, \dots, \tilde{y}_d)^T$ длиной d отсчётов времени.

Шаг 2. Рассчитать ВКФ по \mathbf{u}_k и $\tilde{\mathbf{y}}_k$, чтобы получить векторы $\mathbf{R}_{uy}^k = CCF(u_k, \tilde{y}_k, d)$.

Шаг 3. Рассчитать с помощью МП прогнозируемое значение ошибки $\tilde{e}_{k+d-1} = \text{MLP}(\mathbf{R}_{uy}^k)$.

Шаг 4. Дополнить \tilde{e}_{k+d-1} к выходным данным \tilde{y}_{k+d-1} нейросетевой модели динамического объекта, чтобы получить улучшенный результат прогнозирования \hat{y}_{k+d-1} .

Численные эксперименты

Для иллюстрации применения изложенной методики рассмотрим задачу моделирования нелинейного динамического объекта.

$$y(k) = 0,8 \sin(y(k-1)) + 1,2u(k-1). \quad (10)$$

В качестве входного сигнала будем использовать амплитудно-модулированный псевдослучайный сигнал (APRBS). Пример входного сигнала u и соответствующего ему выходного y длительностью 3 000 отсчётов времени показан на рис. 4.




Рис. 4. Входной сигнал u и выходной сигнал y для обучения GRU

В качестве автономной нейросетевой модели использовалась архитектура GRU. Структура ИНС включала слой 5-мерной ячейки GRU, связанный с полносвязным слоем нейронов размером 5 и слоем регрессии, который используется для построения выходных данных сети. На текущем временном шаге k в сеть GRU поступает сигнал $u(k), \dots, u(k-d+1)$ для прогнозирования сигнала $y(k)$, где d – длина входного сигнала 50. Обучение GRU продолжалось 400 эпох, для минимизации функции потерь использовался алгоритм оптимизации ADAM. Производительность обученной модели GRU при моделировании динамического объекта на тестовом наборе показана на рис. 5.




Рис. 5. Моделируемый GRU-сигнал \tilde{y} (пунктирная линия) и выходной сигнал y динамического объекта (сплошная линия)

Далее ВКФ и ошибка e будут рассчитываться по длине окна $d = 50$, а многослойный перцептрон обучим вычислять ошибку \tilde{e} . Входные и выходные данные перцептрона показаны на рис. 6 и 7. Размер набора обучающих данных для МП составляет 5 000 окон.




Рис. 6. Рассчитанные ВКФ для обучающей выборки




Рис. 7. Сигнал e для обучающей выборки

Структура МП имеет 5 скрытых слоёв, количество нейронов в каждом скрытом слое равно 7.

Затем входные данные u длиной 1 049 вводятся в модель GRU для получения результата прогнозирования \tilde{y} , а затем ВКФ извлекается из 1 000 окон в качестве входных данных перцептрона. Результаты прогнозирования перцептрона показаны на рис. 8.

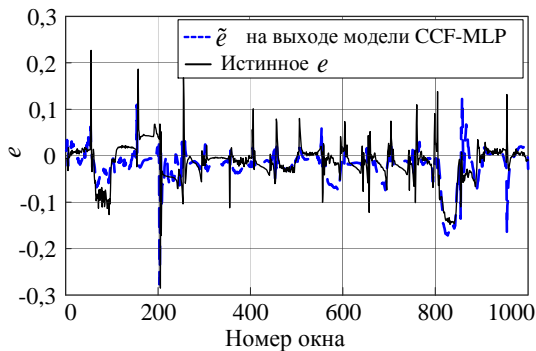


Рис. 8. Сигнал \tilde{e} на выходе модели CCF-MLP

Модель CCF-MLP используется для улучшения результатов прогнозирования модели GRU по формуле $\hat{y} = \tilde{e} + \tilde{y}$.

Таким образом, улучшенная модель GRU+CCF-MLP может быть представлена формулами:

$$\begin{cases} \tilde{y}_k = \text{GRU}(\tilde{y}_{k-1}, u_k); \\ \hat{y}_k = \text{MLP}(\text{CCF}(\tilde{y}_{k-1}, \dots, u_k, \dots)) + \tilde{y}_k. \end{cases} \quad (11)$$

Сравнение результатов прогнозирования показано на рис. 9.

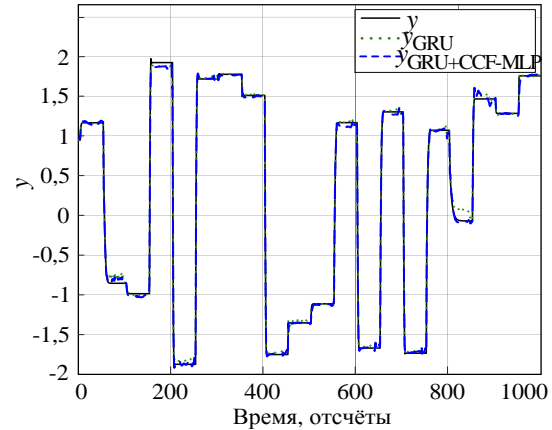


Рис. 9. Сравнение результатов моделирования

В табл. 1 показаны результаты сравнения результатов двух моделей. Видно, что внедрение модели CCF-MLP улучшает результаты прогнозирования модели GRU.

Таблица 1

Сравнение результатов тестирования двух моделей GRU и GRU+CCF-MLP

Нейросетевая модель	RMSE	MAPE
GRU	0,044379	32,9332
GRU+CCF-MLP	0,039344	7,5385

Теперь рассмотрим случай, когда сигнал y на выходе динамического объекта содержит аддитивный шум ϵ_j средним 0 и дисперсией 0,001.

Прогнозирование ошибок e между выходными данными динамического объекта и выходными данными нейросетевой модели GRU динамического объекта с помощью модели CCF-MLP показано на рис. 10.




Рис. 10. Сигнал \tilde{e} на выходе модели CCF-MLP

Сравнение результатов прогнозирования модели GRU и модели GRU, улучшенной с использованием модели CCF-MLP, показано на рис. 11. Сравнение качества нейросетевых моделей в численных характеристиках RMSE и MAPE представлено в табл. 2.

Приведенные результаты показывают, что модель CCF-MLP позволяет улучшить результаты моделирования модели GRU для динамического объекта, когда наблюдаемый сигнал y на выходе динамического объекта содержит помеху.

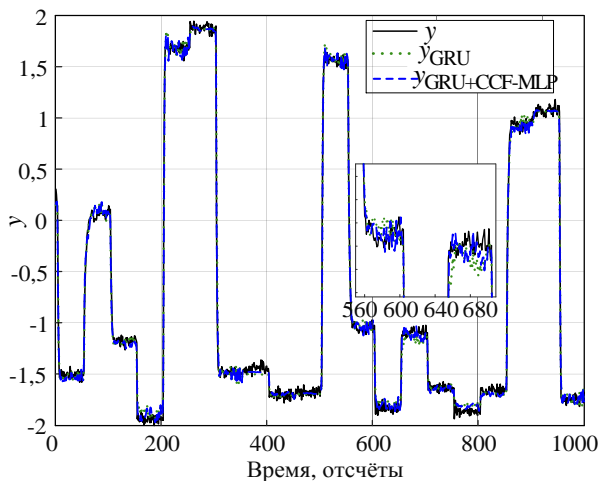


Рис. 11. Сравнение результатов моделирования

Таблица 2

Сравнение результатов тестирования моделей GRU и GRU+CCF-MLP при наличии шума

Нейросетевая модель	RMSE	MAPE
GRU	0,066521	56,0253
GRU+CCF-MLP	0,064535	30,1615

Эксперименты на реальных данных

С целью демонстрации возможности практического применения предложенного метода были проведены эксперименты на данных из реальной системы контроля уровня жидкости, состоящей из двух каскадных резервуаров со свободными выходами, питаемыми насосом. Данные взяты из материалов статьи [16]. Входным сигналом является напряжение $u(k)$, подаваемое на насос, а выходным сигналом является измерение уровня воды $h(k)$ в нижнем резервуаре. Некоторые данные, полученные из системы контроля уровня жидкости, показаны на рис. 12.




Рис. 12. Входные-выходные данные из каскадных резервуаров

Поскольку выпускные отверстия открыты, а резервуары глубокие и имеют большую вертикальную протяженность, результатом является существенно нелинейная динамика, которая меняется в зависимости от уровня воды. Набор данных был сформирован с тактовым периодом 15 отсчетов, шагом дискретизации 4,0 с, и было записано 7 500 отсчетов.

Архитектура и условия обучения нейросети GRU как автономной модели были аналогичны описанным ранее экспериментам.

Далее ВКФ и ошибка e рассчитывались с шириной окна $d=50$, а многослойный перцептрон обучался вычислять ошибку \tilde{e} . Структура МП включала 5 скрытых слоёв, количество нейронов в каждом скрытом слое равно 7. Размер набора обучающих данных для МП составил 3 700 окон.

Входные данные u длиной 750 отсчетов подавались на вход модели GRU для получения результата прогнозирования \tilde{y} , а затем ВКФ рассчитывалась по 701 окну в качестве входных данных МП. Результаты прогнозирования ошибки с помощью обученного МП показаны на рис. 13.



Рис. 13. Сигнал \tilde{e} на выходе модели CCF-MLP

Сравнение результатов прогнозирования модели GRU и модели GRU, улучшенной с использованием модели CCF-MLP, показано на рис. 14.




Рис. 14. Сравнение результатов моделирования

Видно, что модель GRU+CCF-MLP может отслеживать траекторию уровня жидкости лучше, чем одна модель GRU.

В табл. 3 показаны результаты сравнения результатов моделирования моделей GRU и GRU+CCF-MLP для систем контроля уровня жидкости.

Значение RMSE и значение MAPE модели GRU+CCF-MLP относительно меньше, чем у модели GRU, что доказывает эффективность предлагаемого метода на реальных данных.

Таблица 3
Сравнение результатов моделирования моделей GRU и GRU+CCF-MLP для систем контроля уровня жидкости

Нейросетевая модель	RMSE	MAPE
GRU	0,532	19,3977
GRU+CCF-MLP	0,18333	7,0089

Обсуждение

В работе предложена методика улучшения качества моделирования автономной нейросетевой модели с помощью статической нейросети типа многослойный перцептрон, обрабатывающей на входе ВКФ входного и выходного сигнала автономной модели. Корреляционно-нейросетевой блок CCF-MLP в экспериментах с моделированием нелинейного динамического объекта эффективно дополнил автономную нейросетевую модель GRU. Уникальной особенностью CCF-MLP является отсутствие внутреннего механизма памяти, что упрощает процесс обучения и повышает точность прогнозов модели. Это проектное решение снижает сложность вычислений и делает нашу модель более эффективной при решении сложных задач последовательности.

С другой стороны, ВКФ как стратегия линейной динамической локальной оценки расширяет возможности GRU, особенно для задач долгосрочной зависимости, и компенсирует ограничения GRU при обработке определенных долгосрочных моделей. Эта комбинация позволяет модели лучше фиксировать временные корреляции в данных последовательности, улучшая общую производительность.

Стоит отметить, что из-за дифференцируемой природы CCF-MLP объединение его с GRU для построения модели GRU+CCF-MLP дает возможность применять ее в сложных сценариях, таких как синтез модели обратной динамики объекта управления и предиктивное управление по модели (Model Predictive Control, MPC). Этот метод не только сохраняет преимущества GRU, но также обеспечивает более эффективные и точные решения по управлению за счет надежности и гибкости CCF-MLP.

Выводы

В данной работе подробно исследуется возможность использования ВКФ и многослойного перцептрона для улучшения результатов прогнозирования автономных нейросетевых моделей нелинейных динамических объектов. Предлагается методика синтеза улучшенной нейросетевой модели, дополненной по сравнению с исходной обучаемым корреляционно-нейросетевым блоком CCF-MLP.

Результаты показывают, что по сравнению с исходной моделью GRU улучшенная модель GRU с CCF-MLP демонстрирует преимущества в точности моделирования нелинейного динамического объекта. Значения MAPE и RMSE улучшенной модели значительно снизились, что доказывает, что предложенный метод действительно эффективно снижает ошибку прогнозирования. Эксперименты с зашумленными и реальными данными показывают, что предложенный метод улучшения качества модели может использоваться на практике при работе с реальными динамическими объектами и их моделями.

Применение разработанного метода не ограничивается улучшением качества моделирования нейронных сетей GRU. Разработанный метод также может быть использован с другими типами рекуррентных нейронных сетей, таких как LSTM, а также потенциально может принести пользу для улучшения качества моделей других типов.

Литература

1. Шумихин А.Г. Применение нейросетевых динамических моделей в задаче параметрической идентификации технологического объекта в составе системы управления / А.Г. Шумихин, А.С. Бояршинова // Вестник ПНИПУ. – 2015. – № 3. – С. 21–38.
2. Schoukens J. Nonlinear system identification: A user-oriented road map / J. Schoukens, L. Ljung // IEEE Control Systems Magazine. – 2019. – Vol. 39, No. 6. – P. 28–99.
3. Yamada T. Dynamic system identification using neural networks / T. Yamada, T. Yabuta // IEEE transactions on systems, man, and cybernetics. – 1993. – Vol. 23, No. 1. – P. 204–211.
4. Wang J. A fully automated recurrent neural network for unknown dynamic system identification and control / J. Wang, Y. Chen // IEEE Transactions on Circuits and Systems I: Regular Papers. – 2006. – Vol. 53, No. 6. – P. 1363–1372.
5. Legaard C. Constructing neural network based models for simulating dynamical systems / C. Legaard, T. Schranz, G. Schweiger, J. Dragoña // ACM Computing Surveys. – 2023. – Vol. 55, No. 11. – P. 1–34.
6. Gonzalez J. Non-linear system modeling using LSTM neural networks / J. Gonzalez, W. Yu // IFAC-PapersOnLine. – 2018. – Vol. 51, No. 13. – P. 485–489.
7. Bonassi F. Nonlinear MPC for offset-free tracking of systems learned by GRU neural networks / F. Bonassi, C.F. da Silva, R. Scattolini // IFAC-PapersOnLine. – 2021. – Vol. 54, No. 14. – P. 54–59.
8. Al Seyab R.K. Nonlinear system identification for predictive control using continuous time recurrent neural networks and automatic differentiation / R.K. Al Seyab, Y. Cao // Journal of Process Control – 2008. – Vol. 18, No. 6. – P. 568–581.
9. Vaswani A. Attention is all you need / A. Vaswani, N.M. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A.N. Gomez, Ł. Kaiser, I. Polosukhin // Advances in Neural Information Processing Systems. – 2017.
10. Lin T. Focal loss for dense object detection / T. Lin, P. Goyal, R. Girshick, K. He, P. Dollár // IEEE Transactions on Pattern Analysis and Machine Intelligence. – 2020. – Vol. 42, No. 2. – P. 318–327.
11. Madry A. Towards deep learning models resistant to adversarial attacks // arXiv preprint arXiv:1706.06083. – 2017.
12. Gonzalez J. Non-linear system modeling using LSTM neural networks / J. Gonzalez, W. Yu // IFAC-PapersOnLine. – 2018. – Vol. 51, No. 13. – P. 485–489.
13. Елисеев В.Л. Применение функции взаимной корреляции в качестве характеристики динамики нестационарных, нелинейных объектов и нейросетевых моделей / В.Л. Елисеев, С. Ван // Тезисы докл. XXVIII Байкальской Всерос. конф. с междунар. участием «Информационные и математические технологии в науке и управлении». – Иркутск, 2023. – 57 с.
14. Ван С. Обнаружение разладки модели динамического объекта с помощью функции корреляции / С. Ван, В.Л. Елисеев // XXX Междунар. науч.-техн. конф. студентов и аспирантов «Радиоэлектроника, электротехника и энергетика». – М.: Радуга, 2024. – 301 с.
15. Ван С. Нейросетевой метод обнаружения смены режима работы нелинейного динамического объекта /

С. Ван, В.Л. Елисеев // Известия Тульского гос. ун-та. Технические науки. – 2024. – № 3. – С. 48–56.

16. Wigren T. Three free data sets for development and benchmarking in nonlinear system identification / T. Wigren, J. Schoukens // 2013 European control conference (ECC). – Zurich: 2013. – P. 2933–2938.

Ван Сюэчунь

Аспирант каф. управления и интеллектуальных технологий НИУ «МЭИ»

Красноказарменная ул., 13, с. 3, г. Москва, Россия, 111250

ORCID: 0009-0006-1319-6374

Тел.: +7-985-457-43-56

Эл. почта: vansiuech@mpei.ru

Елисеев Владимир Леонидович

Канд. техн. наук, доцент каф. управления

и интеллектуальных технологий НИУ «МЭИ»

Красноказарменная ул., 13, с. 3, г. Москва, Россия, 111250

ORCID: 0000-0002-9341-7475

Тел.: +7-916-914-98-89

Эл. почта: vlad-eliseev@mail.ru

Wang X., Eliseev V.L.

Methodology to improve the quality of neural network modeling of dynamic objects

The problem of neural network modeling of nonlinear dynamic objects using recurrent neural networks is considered. An approach to improve the accuracy of modeling using a static neural network of the «multilayer perceptron» type, that processes correlation dependencies of a dynamic process and approximates the modeling error, is proposed. A technique for synthesis and application of the correlation neural network model CCF-MLP improving the quality of modeling of a conventional recurrent neural network, is formulated. Simulation experiments are carried out with a neural network recurrent network of the GRU type, that models the behavior of a nonlinear dynamic object, as well as GRU with the proposed CCF-MLP model. The improvement in the quality of modeling (RMSE, MAPE) is confirmed in the case of using CCF-MLP both in the presence and absence of noise in the observed data. The practical applicability of the proposed method was tested on a real liquid level control system.

Keywords: cross-correlation function, multilayer perceptron, recurrent neural network, dynamic object modeling, nonlinear dynamic object.

DOI: 10.21293/1818-0442-2024-27-3-92-99

References

1. Shumikhin A.G., Boyarshinova A.S. [Controlled Technological Objects Parametric Identification with Dynamic Neural Network Models]. *Bulletin of Perm National Research Polytechnic University*, 2015, no. 11, pp. 21–38 (in Russ.).

2. Schoukens J., Ljung L. Nonlinear system identification: A user-oriented road map. *IEEE Control Systems Magazine*, 2019, vol. 5, no. 4, pp. 28–99.

3. Yamada T., Yabuta T. Dynamic system identification using neural networks. *IEEE Transactions on Systems, Man, and Cybernetics*, 1993, vol. 23, no. 1, pp. 204–211.

4. Wang J., Chen Y. A fully automated recurrent neural network for unknown dynamic system identification and control. *IEEE Transactions on Circuits and Systems I: Regular Papers*, 2006, vol. 53, no. 6, pp. 1363–1372.

5. Legaard C., Schranz T., Schweiger G., Drgoňa J. Constructing neural network based models for simulating dynamical systems. *ACM Computing Surveys*, 2023, vol. 55, no. 11, pp. 1–34.

6. Gonzalez J., Yu W. Non-linear system modeling using LSTM neural networks. *IFAC-PapersOnLine*, 2018, vol. 51, no. 13, pp. 485–489.

7. Bonassi F., da Silva C.F., Scattolini R. Nonlinear MPC for offset-free tracking of systems learned by GRU neural networks. *IFAC-PapersOnLine*, 2021, vol. 54, no. 14, pp. 54–59.

8. Al Seyab R.K., Cao Y. Nonlinear system identification for predictive control using continuous time recurrent neural networks and automatic differentiation. *Journal of Process Control*, 2021, vol. 18, no. 6, pp. 568–581.

9. Vaswani A., Shazeer N.M., Parmar N., Uszkoreit J., Jones L., Gomez, A.N., Kaiser Ł., Polosukhin I. Attention is all you need. *Advances in Neural Information Processing Systems*, 2017.

10. Lin T., Goyal P., Girshick R., He K., Dollár P. Focal loss for dense object detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020, vol. 42, no. 2, pp. 318–327.

11. Madry A. Towards deep learning models resistant to adversarial attacks. *arXiv preprint arXiv:1706.06083*, 2017.

12. Gonzalez J., Yu W. Non-linear system modeling using LSTM neural networks. *IFAC-PapersOnLine*, 2018, vol. 51, no. 13, pp. 485–489.

13. Eliseev V.L., Wang X. [Application of the cross-correlation function as a characteristic of the dynamics of non-stationary, non-linear objects and neural network models]. *Materials of the 28th Baikal All-Russian Conference with international participation «Information and Mathematical Technologies in Science and Management»*. Irkutsk, 2023, 57 p. (in Russ.).

14. Wang X., Eliseev V.L. [Detecting Dynamic Object Model Disorders Using Correlation Function]. *Materials of the Technical Conference of Students and Postgraduates «Radio Electronics, Electrical Engineering and Power Engineering»*. M.: Raduga, 2024, 301 p. (in Russ.).

15. Wang X., Eliseev V.L. [Neural Network Method for Detecting Changes in the Operating Mode of a Nonlinear Dynamic Object]. *News of the Tula State University. Technical Sciences*, 2024, no. 3, pp. 48–56 (in Russ.).

16. Wigren T., Schoukens J. Three free data sets for development and benchmarking in nonlinear system identification. *2013 European Control Conference (ECC)*. Zurich, 2013, pp. 2933–2938.

Xuechun Wang

Postgraduate student, Department of Control and Intelligent Technologies, National Research University «Moscow Power Engineering Institute»

13, Krasnokazarmennaya st., bldg. 3, Moscow, Russia, 111250

ORCID: 0009-0006-1319-6374

Phone: +7-985-457-43-56

Email: vansiuech@mpei.ru

Vladimir L. Eliseev

Candidate of Sciences in Engineering, Associate Professor, Department of Control and Intelligent Technologies, National Research University «Moscow Power Engineering Institute»

13, Krasnokazarmennaya st., bldg. 3, Moscow, Russia, 111250

ORCID: 0000-0002-9341-7475

Phone: +7-916-914-98-89

Email: vlad-eliseev@mail.ru