

Эволюционная динамика нейронной сети глубокого обучения в нестационарной среде

Ю. И. Нечаев, А. А. Турчак

Санкт-Петербургский государственный морской технический университет
nechaev@mail.ifmo.ru

Аннотация. Обсуждается парадигма нейронной сети (ИНС) глубокого обучения в сложной динамической среде. Рассматривается раздельное обучение скрытых слоев ИНС глубокого обучения в условиях нестационарности среды взаимодействия. Поле обучения и верификации ИНС изменяют чувствительность к входным параметрам и степени их влияния на прогнозируемые результаты. Предложены постулаты разработки методов интерпретации динамики ИНС глубокого обучения. Эффективность ИНС в нестационарной среде существенно повышена на счет модификации концепции глубокого и итерационного обучения.

Ключевые слова: сеть глубокого обучения; нестационарная среда; эволюционная динамика

I. ВВЕДЕНИЕ

Эволюционная динамика искусственной нейронной сети (ИНС) глубокого обучения определяется сложной структурой взаимодействующих объектов. Одной из типичных задач, связанных с применением ИНС глубокого обучения является поведение морского динамического объекта (МДО) в нестационарном ледовом поле (рис. 1).

Стратегия управления в этих условиях требует применения современных информационных технологий и моделей интерпретации при большом числе взаимодействующих компонент динамической среды взаимодействия [1–5].

Ниже рассмотрены теоретические аспекты интерпретации динамики ИНС глубокого обучения при движении МДО в нестационарном поле различной конфигурации. В основу решения задачи интерпретации положены: C_j ($j=1, \dots, m$) – вектор элементов, определяющих модель взаимодействия; X_i ($i=1, \dots, n$) – вектор параметров с ограничениями $(X_i)_{\min} \leq (X_i) \leq (X_i)_{\max}$; требования к объекту моделирования $V_j(X, C) \oplus A_j(C)$, где V_j – оценка j -го качества генерируемого варианта решения, $A_j(C)$ – требования к j -му качеству интерпретируемой модели, а \oplus – знак отношения; $Z(X, C) \text{ extg}$ – критерий эффективности, определяющий наилучший вариант решения.



Рис. 1. Функциональная модель контроля динамики ИНС в нестационарной среде

II. НЕСТАЦИОНАРНОЕ ПОЛЕ ФОРМИРОВАНИЯ ДИНАМИКИ ИНС

Разработка методов интерпретации динамики ИНС глубокого обучения осуществляется в рамках следующих постулатов [1]:

Постулат 1. Математическое описание динамики ИНС представляет собой сильно связанную структуру с динамически изменяющимися связями, что затрудняет реализацию процедур интерпретации и распараллеливания вычислений.

Постулат 2. Процессы взаимодействия в нестационарной среде зависят как от внешних, так и от внутренних факторов, связанных с адаптацией и самоорганизацией. Это приводит к различиям в количестве операций над элементами эволюционирующей системы и существенной неоднородности вычислений с

использованием методов балансировки вычислительной загрузки.

Постулат 3. Симптомы и причины возникновения критических явлений в нестационарной среде требуют привлечения современного аппарата анализа закономерностей и феноменов взаимодействия, многообразия внешних и внутренних факторов. Интеграция поведения МДО в сложных условиях требует использования технологий Data Mining и Soft Computing [1].

Постулат 4. Критические явления в процессе эволюции МДО относятся к редким событиям, что затрудняет использование вероятностных оценок и соответствующего риска при выполнении требований модельного воспроизведения всего ансамбля взаимодействующих МДО и возможных состояний среды взаимодействия. В результате увеличиваются общие требования к вычислительным ресурсам и эффективности их использования в критических режимах.

Постулат 5. Взаимодействующие структуры реального взаимодействия в нестационарной среде содержат большие объемы данных, хранение и обработка которых ведется в рамках технологии Big Data [1].

III. ПАРАДИГМА ИНС ГЛУБОКОГО ОБУЧЕНИЯ В НЕСТАЦИОНАРНОЙ СРЕДЕ

ИНС глубокого обучения (рис. 2) имеет множество скрытых слоев, подверженных разделению в условиях нестационарности среды взаимодействия. Поле обучения и верификации ИНС изменяют чувствительность к входным параметрам и степени их влияния на прогнозируемые результаты. ИНС может воспринимать практически любое число входных параметров. Эффективность ИНС в нестационарной среде существенно повышена на счет модификации концепции *глубокого* и *итерационного* обучения [2], [4].




Рис. 2. Интегрированная ИНС с множеством скрытых слоев: (1 – 3) – входной и m - выходной слой

Рассмотрим некоторые особенности модифицированного алгоритма *глубокого обучения* на основе следующих процедур:

Процедура 1. Переход от *усеченного* линейного преобразования (Rectified Linear Unit – RLU) к более сложной модели, отображающей динамические процессы функции интерпретации.

Процедура 2. Учет пространственно-временной конфигурации внешней среды, требующей использования модифицированной модели *стохастического* градиентного спуска (Stochastic Gradient Descent – SGD) на каждом шаге оценки градиента ошибки интерпретации.

Процедура 3. Разработка алгоритма глубокого обучения на основе нормализации формируемой выборки (Batch Normalization) для обеспечения стабилизации текущих оценок для каждого входа нейронов.

Концептуальные решения, формирующие структуру моделей динамики взаимодействия на основе процедур 1 – 3, представляет собой отображение $f: U \rightarrow U^*$ интегрированной модели глубокого обучения ИНС на основе следующих определений.

Определение 1. Отображение f характеризует преобразование информации об особенностях эволюционной динамики интерпретируемой системы глубокого обучения в виде направленного множества:

$$U(t_0, t_k) \Rightarrow U^*(R_1, R_2, R_3) [f_t \in \Omega] \quad (1)$$

где $U(t_0, t_k)$ – многорежимное управление, обеспечивающее функционирование ИНС на интервале реализации; $U^*(R_1, R_2, R_3)$ – функция интерпретации, формирующая управление в зависимости от сложности и неопределенности контролируемой ситуации при выполнении задач по алгоритму глубокого обучения; Ω – область допустимых значений параметров взаимодействия.

Определение 2. Функции интерпретации для выделенных режимов R_1, R_2, R_3 задач глубокого обучения в условиях неопределенности определяется кортежем:

$$U^*(R_1, R_2, R_3) = \langle U_1(Int), U_2(G), U_3(F) \rangle, \quad (2)$$

где $U_1(\bullet), U_2(\bullet), U_3(\bullet)$ – структуры управления, реализующие модели функций интерпретации $U_1(Int)$, пространственно-временной конфигурации внешней среды $U_2(E)$ и нормализации выборки $U_3(N)$.

Определение 3. Обеспечение многорежимного управления достигается за счет реализации ансамбля нейроконтроллеров (рис.3) [3], осуществляющего режим управления R_1 на базе процедуры перехода к более сложной модели интерпретации динамики взаимодействия; режим управления R_2 , реализующий стратегию учета конфигурации внешней среды; режим управления R_3 нормализации формируемой выборки данных для обеспечения стабилизации текущих оценок для каждого входа нейронов.

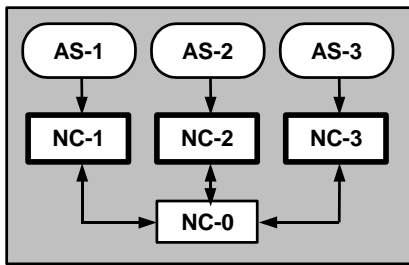


Рис. 3. Ансамбль нейроконтроллеров NC-1, NC-2, NC-3; AS-1, ..., AS-3 – области специализации нейроконтроллеров; $F(\lambda)$ – распределяющая функция; NC-0 – управляющий нейроконтроллер.

Из рис. 3 видно, что ансамбль содержит нейроконтроллеры, каждый из которых имеет свою область специализации AS_i ($i=1,2,3$), формирующую управляющий сигнал. Функция нейроконтроллера NC-0 состоит в выработке номера i ($1 \leq i \leq 3$) для каждого текущего значения $\lambda \in \Lambda$ в соответствии с зависимостями $F(\lambda)$. Этот номер указывает, какой из нейроконтроллеров NC_i должен осуществлять управление при данном $\lambda \in \Lambda$. Переход от одного нейроконтроллера к другому устанавливаются с помощью распределяющей функции $F(\lambda)$.

При использовании разработанной стратегии интерпретации ИНС глубокого обучения на базе определений 1–3 сохраняется исходная модель, заложенная при начальном обучении, а новые параметры вносятся без проблемы *забывания*. Эта необычная сеть имеет множество скрытых слоев, подверженных разделному обучению в режиме экстренных вычислений (Urgent Computing – UC) [5]).

IV. АЛГОРИТМ И СТРАТЕГИИ УПРАВЛЕНИЯ

Процедуры, реализующие разработанную стратегию динамической модели глубокого обучения, выполняется в виде последовательности шагов, представленных на рис. 4.

Задача прогнозирования поведения МДО на основе разработанного алгоритма представляет цепочку преобразований:

$$X_1(T, S) \Rightarrow Y_1(Out), \dots, X_n(T, S) \Rightarrow Y_n(Out), \quad (3)$$

где компоненты $X_1(T, S), \dots, X_n(T, S)$ определяют функции интерпретации на каждом шаге эволюции, а $Y_1(Out), \dots, Y_n(Out)$ – результаты прогноза исследуемого параметра.

Реализация функции управления при планировании операций контроля эволюционной динамики МДО зависит от вектора параметров $X \in R^n$, определяющих поведение и вектора состояния среды взаимодействия $W \in R^m$ в заданном режиме. Если $[X, W] \in A$, то генерируемое решение с вектором параметров X обеспечивает поддержание состояния МДО, характеризуемого вектором W . Если же $[X, W] \in B$ то планируемые операции приводят к неэффективной работе системы поддержки управленческих решений. Приведенные условия

определяют решение задачи выбора стратегических решений

$$x^*(X, W) > 0, \forall (X, W) \in A \quad (4)$$

$$x^*(X, W) < 0, \forall (X, W) \in B, x^* \in X^* \quad (5)$$

где x^* – выбранный класс разделяющих функций.

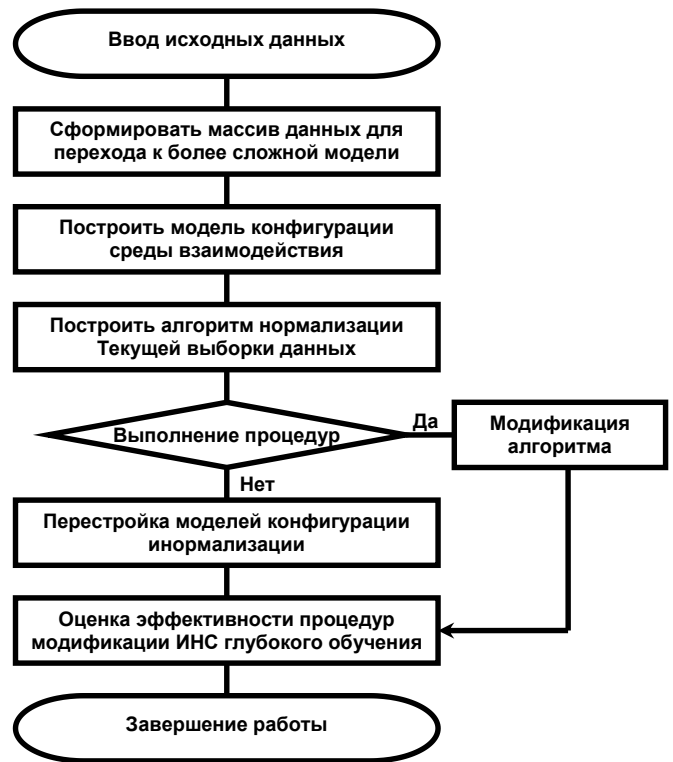


Рис. 4. Алгоритм преобразования информации в модифицированной ИНС глубокого обучения

Генерация альтернатив позволяет сформировать обобщенный сценарий развития ситуации при формировании стратегии глубокого обучения в нестационарной динамической среде. Используя понятия теории принятия решений, можно идентифицировать следующие типы переменных:

$$\langle Str(P), Out(P), E(P) \rangle \quad (6)$$

где $Str(P)$ – стратегии планирования; $Out(P)$ – исходы, которые можно осуществить при интерпретации ситуации; $E(P)$ – эффективность, которая выражает соотношения между стратегиями планирования и исходами.

V. ЭФФЕКТИВНОСТЬ СТРАТЕГИЧЕСКИХ РЕШЕНИЙ

Функция цели при реализации динамики ИНС глубокого обучения определяет рациональные траектории

МДО из исследуемого состояния. Маневренность состояния характеризуется суммарной величиной вариантов рационального управления для всех состояний, через которые проходит траектория движения МДО в рассматриваемой нестационарной среде:

$$M_i = k_m (R_i / N_i)^{(1-k)} (1 - \prod_{j=0}^n (1 - M_j)), \quad (7)$$

где M_i – маневренность i -го состояния; R_i – количество генерируемых траекторий, начинающихся в i -м состоянии; N_i – общее количество целевых траекторий, начинающихся в i -м состоянии; k – коэффициент учета маневренности M_j следующих состояний (от 0.6 до 1.0).

Управляющее воздействие, с помощью которого устанавливается однозначность решения задачи адаптивной идентификации, определим как $u(t)$. С учетом этих обозначений можно записать:

$$S(t)(a(t), u(t)) \in S(t)^*(a(t), u(t)), \quad (8)$$

где $S(t), S(t)^*$ – текущая и эталонная ситуации; $a(t)$ – параметры задачи, решаемой в момент времени t .

Интервал времени, на котором решается текущая задача оперативного контроля при известных параметрах и управляющих воздействиях, обозначим как $[t_0, t_k]$. Тогда необходимые данные определяются структурами:

$$D_{1i} \in \{D_1\}, (i = 1, \dots, m), D_{2j} \in \{D_2\}, (j = 1, \dots, n), \quad (9)$$

$$S(t)(a(t), u(t)) \in S(t)^*(a(t), u(t)),$$

где m, n – количество данных измерений, моделирования и априорной информации, характеризующих текущую ситуацию, а символ \llcorner определяет упорядочение данных по степени важности.

Эффективность реализации динамики ИНС глубокого обучения в нестационарной среде определяется оператором, характеризующим стратегию поведения МДО:

$$F = \{F_1, \dots, F_N\} : x_i(t) = F(W_1, \dots, W_k, x_1^0, \dots, x_n^0), \quad (10)$$

где W – множество исходных переменных, характеризующих состав, структуру и свойства компонентов МДО и окружающей нестационарной среды; $x_i(t)$ – множество переменных состояния и объектов моделирования, характеризующих преобразование информации при формировании скрытых слоев модифицированной ИНС.

СПИСОК ЛИТЕРАТУРЫ

- [1] Нечаев Ю.И. Современные проблемы информатики и вычислительной техники. Санкт-Петербург, Арт-Экспресс, 2018. 384 с.
- [2] Николаенко С., Кадури А., Архангельская Е. Глубокое обучение. Санкт-Петербург: Питер, 2018. 480 с.
- [3] Brusov V. S., Tiumentsev Yu. V. High performance aircraft flight control based on artificial neural networks // Proc. Of the RRDPAE-96, Part 1, p.p.97–100 (1997).
- [4] Hinton G et al. A fast learning algorithm for deep belief nets // Neural Computation, 2006, v.58, №7, p.p. 1527–1554.
- [5] Urgent Computing Workshop 2007. Argonne National Lab, University of Chicago, April 25-26, 2007. [Электронный ресурс]: <http://spruce.teragrid.org/workshop/urgent07.php>