

ОСОБЕННОСТИ СИНХРОНИЗАЦИИ НЕЙРОННЫХ СЕТЕЙ В РАСПРЕДЕЛЁННЫХ СИСТЕМАХ

***Аннотация.** Анализируются современные методы синхронизации нейронных сетей, функционирующих в распределённой среде. Предложен комплексный метод численной оценки эффективности синхронизации сетей. Он основан на использовании трех метрик: расстояния весов, корреляции выходных сигналов и времени достижения синхронизации. Представлены элементы и результаты математического моделирования процесса синхронизации сетей.*

D.V. Sazonova¹, P.P. Urbanovich^{1,2}

¹Belarusian State Technological University
Minsk, Belarus

The John Paul II Catholic University of Lublin
Lublin, Poland

FEATURES OF SYNCHRONIZATION OF NEURAL NETWORKS IN DISTRIBUTED SYSTEMS

***Abstract.** Modern methods for synchronizing neural networks operating in a distributed environment are analyzed. A comprehensive method for numerically assessing the effectiveness of network synchronization is proposed. It is based on three metrics: weight distance, output signal correlation, and synchronization time. Elements and results of mathematical modeling of the network synchronization process are presented.*

Синхронизация параметров удаленных нейронных сетей по каналам связи является ключевым элементом современных систем безопасного машинного обучения и распределенных вычислений. Основная задача заключается в достижении равенства весовых коэффициентов синхронизируемых нейронных структур при ограниченной полосе пропускания, возможных сетевых задержках и с учетом вероятного противодействия нелегитимной стороны [1].

Одним из классических примеров является Tree Parity Machine (TPM) [2] – искусственная нейронная сеть, применяемая как модель для изучения синхронизации и криптографических протоколов обмена ключами. При взаимодействии двух TPM сетей *A* и *B*, каждая из которых имеет

одинаковую архитектуру, возможно достижение состояния, при котором весовые коэффициенты сетей становятся идентичными: $W_A = W_B$.

Настоящая работа рассматривает три подхода к синхронизации сетей:

1) взаимное обучение (Mutual Learning, ML) – классическое взаимное обучение с обменом выходными параметрами (сигналами);

2) синхронизация по модели Курамото (Kuramoto Synchronization, KS) – фазовая синхронизация осцилляторов, адаптированная под нейронные сети.

3) событийно-управляемое взаимное обучение (Event-Triggered Mutual Learning, ETML) – событийно-управляемая модификация, снижающая количество обменов по сети.

Модель Tree Parity Machine (древовидная машина четности) [2]. ТРМ состоит из трех уровней: входного слоя, скрытого слоя с K нейронами и выходного слоя. Локальное состояние каждого скрытого нейрона σ_i вычисляется как:

$$\sigma_i = \text{sign} \left(\frac{1}{\sqrt{N}} \sum_{j=1}^N w_{ij} x_{ij} \right),$$

где $x_{ij} \in \{-1, +1\}$ – входные сигналы, $w_{ij} \in [-L, L]$ – целочисленные веса, N – число входов на каждый скрытый нейрон.

Выход сети:

$$\tau = \prod_{i=1}^K \sigma_i.$$

Обновление весов на шаге $t+1$ процесса синхронизации производится только при совпадении выходов сетей ($\tau_A = \tau_B$) по правилу Хебба (существуют и иные правила [2]):

$$w_{ij}^{(t+1)} = w_{ij}^{(t)} + \eta x_{ij} \sigma_i \Theta(\sigma_i \tau),$$

где η – коэффициент обучения, Θ – индикатор функции совпадения знаков.

Синхронизация на основе модели Курамото [3]. В этом случае каждый весовой коэффициент (или группа весов) нейрона рассматривается как фазовый осциллятор с собственной частотой θ_i .

Модель синхронизации описывается выражением:

$$\frac{d\theta_i}{dt} = \omega_i + \frac{K_s}{N} \sum_{j=1}^N \sin(\theta_j - \theta_i),$$

где K_s — коэффициент связи.

В модели Курамото взаимодействия между двумя сетями могут быть смоделированы как связи между соответствующими осцилляторами. Эти связи влияют на фазовое сдвигающее воздействие, которое способствует или мешает синхронизации сетей.

Полная синхронизация сетей наступает, когда фазы сходятся и различия между ними становятся постоянными или исчезают. Частичная синхронизация сетей — наличествуют сохраняющиеся фазовые сдвиги.

Визуализация переходных процессов и установление условий, при которых сети приходят в синхронное состояние, а также исследование устойчивости процесса синхронизации нейронных сетей, влияние параметров взаимодействия, частоты и начальных условий производилось нами на основе численной симуляции модели Курамото с помощью искусственного интеллекта.

Событийно-управляемое обучение [4]. В этом методе обновление весов инициируется не на каждой итерации, а только при существенных изменениях состояния выхода сети, т.е. если

$$\left| \tau_A^{(t)} - \tau_A^{(t-1)} \right| > \delta,$$

где δ — некоторый заданный порог наступления события.

Правило обновления состояния параметров сети сравнительно классической системы модифицируется следующим образом:

$$w_{ij}^{(t+1)} = w_{ij}^{(t)} + E(t)\eta x_{ij}\sigma_i\Theta(\sigma_i\tau),$$

где $E(t)$ — событийная функция:

$$E(t) = \begin{cases} 1, & \text{если } \left| \tau_A^{(t)} - \tau_A^{(t-1)} \right| > \delta, \\ 0, & \text{иначе.} \end{cases}$$

Такой подход сокращает количество коммуникаций сетей без ухудшения точности процесса синхронизации.

Методика количественной оценки эффективности синхронизации. Для сравнения рассмотренных методов синхронизации используем три метрики:

1) среднее нормированное расстояние $\Delta\tilde{W}(t)$ между весовыми коэффициентами сетей:

$$\Delta\tilde{W}(t) = \frac{1}{KNL} \sum_{i=1}^K \sum_{j=1}^N |w_{ij}^{A(t)} - w_{ij}^{B(t)}|.$$

2) корреляция выходов сетей:

$$Corr_{out} = \frac{1}{T} \sum_{t=1}^T \tau_A^{(t)} \tau_B^{(t)}.$$

3) время синхронизации сетей:

$$T_{sync} = \min\{t: \Delta\tilde{W}(t) \leq b\}.$$

где b – установленный верхний порог достижения синхронизации.

На основе вышеприведенных метрик формируется интегральная оценка эффективности:

$$E_{sync} = \alpha_1(1 - \Delta\tilde{W}_{final}) + \alpha_2 Cor_{out} + \alpha_3 \left(1 - \frac{T_{sync}}{T_{max}}\right),$$

где $\Delta\tilde{W}_{final}$ – нормированное конечное значение расстояния между весами сетей; $\alpha_1, \alpha_2, \alpha_3$ – весовые коэффициенты важности метрики ($\alpha_1 + \alpha_2 + \alpha_3 = 1$); T_{max} – верхняя граница числа итераций процесса синхронизации.

Для проверки корректности использования выбранных метрик сравнения методов синхронизации нами использовалась модель ТРМ: $K = 3$ – классический выбор в моделях ТРМ, $N = 200$, $L = \pm 3$ – дает оптимальный баланс (при больших L процесс синхронизации замедляется экспоненциально, при малых (например, $L = \pm 1$ или ± 2) – слишком быстрое «прилипание» к границе весов), $T_{max} = 2000$ – достаточный горизонт моделирования (учитываются случайные задержки и модели, которые сходятся медленнее), $b = 10^{-3}$ – чувствительный, но не слишком строгий порог, дает возможность достаточно точного определения момента синхронизации (более строгий порог (10^{-4} , 10^{-5}) не имеет смысла, т.к. веса – дискретные).

В табл.1 представлены полученные экспериментальные данные.

Таблица 1 – Сравнительные результаты эффективности методов синхронизации сетей на основе разных метрик

Метод	ΔW_{final}	$Corr_{out}$	T_{sync}	E_{sync}
ML	0.08	0.91	1800	0.652
KS	0.05	0.95	1600	0.734
ETML	0.03	0.97	1200	0.812

На графиках (рис. 1) приведена динамика изменения расстояния между весами $\Delta W(t)$ и степень корреляции выходных сигналов ($Corr_{out}(t)$) сетей для трех исследованных методов синхронизации.

Из анализа графиков следует, что:

- метод ETML демонстрирует наибольшую скорость сходимости весов сетей и соответственно – ускоренный рост корреляции;
- ML обеспечивает стабильность процесса, но требует большего числа итераций (шагов).

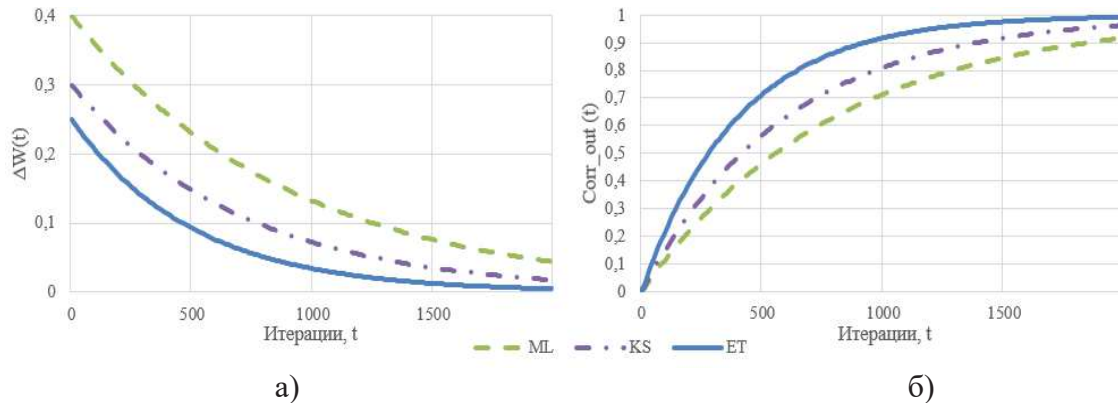


Рис. 1 – Динамика изменения расстояния между весами (а) и коэффициента корреляции между выходными сигналами (б) синхронизируемых нейронных сетей

Кроме того отмечено, что метод ETML сокращает время синхронизации на 33 % по сравнению с моделью KS. Минимальное расхождение весов ($\Delta W_{final}=0.03$) и максимальная корреляция ($Corr_{out} = 0.97$) указывает на наибольшую точность среди приведенных методов. Кроме того, метод ETML требует на 40–50 % меньше шагов сетевых обменов. Модель KS обеспечивает хорошую устойчивость, но менее эффективна при низком коэффициенте связи.

Таким образом, событийно-управляемый подход (ETML) является наиболее сбалансированным по критериям скорости, точности и сетевой нагрузки.

Список использованных источников

1. Урбанович П. П. Киберпространство: тренды, угрозы и безопасность // Интеграция и развитие научно-технического и образовательного сотрудничества – взгляд в будущее: сборник статей II Междунар. научно-техн. конф. "Минские научные чтения - 2019", Минск, 11–12.12.2019: в 3 т. Т. 3. – Минск: БГТУ, 2020. – С. 180–185.
2. Урбанович П. П., Плонковски М. Д., Долецки М. Нейросетевые технологии в криптографических приложениях: монография. Минск: БГТУ, 2024. – 223 с.
3. Kuramoto Model-Based Analysis Reveals Oxytocin Effects on Brain Network Dynamics / Zheng S. et al. // J. Neural Syst. 2022 Feb;32(2):2250002. DOI: 10.1142/S0129065722500022.

4. Master-slave synchronization of neural networks with time-varying delays via the event-triggered control / Zhou, J. et al. // Mathematical and Computer Modelling of Dynamical Systems, 2020, 26(4):1–17. DOI:10.1080/13873954.2020.1777567.

УДК 338.1

А.Я. Салахов

Белорусский национальный технический университет
Минск, Беларусь

СКВОЗНЫЕ ЦИФРОВЫЕ ТЕХНОЛОГИИ КАК КАРКАС ТРАНСФОРМАЦИИ ЭКОНОМИКИ: НА ПРИМЕРЕ ЛОГИСТИКИ И РИТЕЙЛА

***Аннотация.** Сквозные цифровые технологии формируют единый каркас современной экономики, пронизывая все отрасли. Элементы системы: искусственный интеллект для анализа данных, 5G и IoT для передачи информации, и кибербезопасность как "иммунитет" защиты. На примере логистики и ритейла показано, как эти технологии создают самооптимизирующиеся экосистемы - от умных складов до персонализированных сервисов.*

A.Y. Salakhov

Belarusian National Technical University
Minsk, Belarus

END-TO-END DIGITAL TECHNOLOGIES AS A FRAMEWORK FOR ECONOMIC TRANSFORMATION: THE CASE OF LOGISTICS AND RETAIL

***Abstract.** End-to-end digital technologies form a single framework of the modern economy, permeating all industries. The elements of the system include artificial intelligence for data analysis, 5G and IoT for information transmission, and cybersecurity as a "defense immunity". The examples of logistics and retail show how these technologies create self-optimizing ecosystems, from smart warehouses to personalized services.*

Работа направлена на комплексный анализ роли сквозных технологий как драйвера цифровой трансформации современной экономики. Основная цель работы заключается в системном исследовании воздействия технологического кластера, включающего искусственный интеллект, интернет вещей, связь пятого поколения и кибербезопасность, на преобразование традиционных отраслей экономики. В рамках достижения поставленной цели решаются