

Глубокие нейронные сети в информационно-управляющих системах

А.В. Макаренко
avm.science@mail.ru

Научно-исследовательская группа «Конструктивная Кибернетика»
Москва, Россия, www.rdcn.ru

Институт проблем управления РАН
Москва, Россия



Заседание Бюро ОЭММПУ РАН
29 мая 2018 г.
РАН, Москва, Россия

- ❶ Общие положения
 - Обзор мировых тенденций
 - Глубокое обучение
- ❷ Теоретические исследования ИПУ РАН
 - Направления
 - Синхронизация хаоса
 - Бифуркации дискретных отображений
- ❸ Примеры прикладных работ ИПУ РАН
 - Система распознавания вторжений в «Облако»
 - Обнаружение подвижных подводных объектов
 - Защита магистрального трубопровода
- ❹ Заключение

Содержание раздела



- ❶ Общие положения
 - Обзор мировых тенденций
 - Глубокое обучение
- ❷ Теоретические исследования ИПУ РАН
 - Направления
 - Синхронизация хаоса
 - Бифуркации дискретных отображений
- ❸ Примеры прикладных работ ИПУ РАН
 - Система распознавания вторжений в «Облако»
 - Обнаружение подвижных подводных объектов
 - Защита магистрального трубопровода
- ❹ Заключение

Информационно-управляющие системы




- Сложность систем управления и доля их цифровых реализаций неуклонно растёт.
- Инженеры перестают «бояться» работать на границе устойчивости.

Информационно-управляющие системы



- Во многих сложных информационно-управляющих системах стоимость алгоритмического и программного обеспечения достигает до 70% от стоимости системы в целом.


Информационно-управляющие системы



- Повышение тактико-технических характеристик системы, в рамках модернизации (в пределах 2-3-х поколений), зачастую возможно производить за счёт замены алгоритмического и программного обеспечения.

Синтез алгоритмов распознавания


Классическая математическая статистика, стат. радиотехника, и т.п.



- Стоимость машинного времени и стоимость хранения данных неуклонно снижаются.
- Во многих отраслях ощущается острая нехватка профильных специалистов.

Синтез алгоритмов распознавания


Классические алгоритмы машинного обучения



МАШИННОЕ ОБУЧЕНИЕ – обширный (центральный) подраздел искусственного интеллекта, изучающий методы построения алгоритмов, способных обучаться.

Синтез алгоритмов распознавания


Глубокие нейронные сети



ГЛУБОКИЕ НЕЙРОННЫЕ СЕТИ – это многослойные искусственные нейронные сети, с числом внутренних (скрытых) слоёв более одного, обучаемые как единое целое.

Синтез алгоритмов распознавания

Модифицированные глубокие нейронные сети



- Активно развиваются системы слабого искусственного интеллекта.
- Исследования ведутся даже в ряде консервативных областей: АСУТП химических заводов; управление авто- и морским транспортом; вооружение, медицина, юриспруденция, и т.п.

Определение понятия

ГЛУБОКОЕ ОБУЧЕНИЕ – набор алгоритмов машинного обучения, которые пытаются моделировать иерархические абстракции в данных, используя архитектуры, состоящие из каскадного множества нелинейных преобразований (фильтров).

Автор термина Deep Learning:




Рина Дехтер (Rina Dechter),
род. 1950 г.

R. Dechter, “Learning While Searching in Constraint-Satisfaction-Problems”,
Proceedings of the 5th National
Conference on Artificial Intelligence,
vol. 1. Philadelphia, PA, August 11-15,
1986. [Читать...](#)

Определение понятия

ГЛУБОКОЕ ОБУЧЕНИЕ – набор алгоритмов машинного обучения, которые пытаются моделировать иерархические абстракции в данных, используя архитектуры, состоящие из каскадного множества нелинейных преобразований (фильтров).


Пример иерархических абстракций в данных (распознавание изображений):



Определение понятия

ГЛУБОКОЕ ОБУЧЕНИЕ – набор алгоритмов машинного обучения, которые пытаются моделировать иерархические абстракции в данных, используя архитектуры, состоящие из каскадного множества нелинейных преобразований (фильтров).

Пример архитектуры алгоритма:




Начало новейшей истории

[ImageNet](#) – база данных аннотированных изображений, предназначенная для отработки и тестирования алгоритмов распознавания образов и машинного зрения. Для категоризации объектов на изображениях используется семантическая сеть [WordNet](#). База данных определяет 1000 классов и по состоянию на 2016 год содержит около 10 млн. изображений.


Начало новейшей истории

ImageNet – база данных аннотированных изображений, предназначенная для отработки и тестирования алгоритмов распознавания образов и машинного зрения. Для категоризации объектов на изображениях используется семантическая сеть **WordNet**. База данных определяет 1000 классов и по состоянию на 2016 год содержит около 10 млн. изображений.




Alex Krizhevsky в 2012 году в соревновании по распознаванию изображений ImageNet применил подход на основе глубоких нейронных сетей. Его сеть AlexNet победила с существенным отрывом. Это дало исходный толчок к буму Deep Learning, который мы наблюдаем в настоящее время.

A. Krizhevsky, I. Sutskever, Geoffrey E. Hinton, ImageNet Classification with Deep Convolutional Neural Networks.




Составляющие успеха – Данные для обучения

Тотальный перевод информации в электронную (машиночитаемую) форму. Наборы данных для обучения и тестирования алгоритмов машинного обучения увеличиваются в размерах, повышается их качество и разнообразие. Стоимость добычи данных существенно снижается.



Источник и расшифровка диаграммы: [I. Goodfellow, Y. Bengio, and A. Courville, Deep Learning. MIT Press, 2016.](#)

Составляющие успеха – Аппаратные вычислительные ресурсы



- ASCI White
- ноябрь 2000 – июнь 2002
- 12.3 Тфлопс
- 110 миллионов долларов США
- 6 МВт
- 106 тонн.



- GPU NVIDIA Volta
- 3-й квартал 2017
- 15.0 Тфлопс
- 1 700 долларов США
- 300 Вт
- 370 г.

Составляющие успеха – Программное обеспечение

С программным обеспечением в области Deep Learning сложилась уникальная ситуация, кардинально отличающаяся от принятых «правил игры» в других научно-технических областях:

- Подавляющее большинство библиотек и фреймворков – бесплатно.
- Исходный код основных библиотек и фреймворков – открыт.
- Обучающие материалы – бесплатны и свободно доступны.
- Широкие и отзывчивые группы поддержки.

UC Berkeley Caffe, Google TensorFlow, Microsoft CNTK, ...

Почему сети работают?

Theorem (Universal Approximation Theorem FFNN, George Cybenko, 1989)

Искусственная нейронная сеть прямой связи (англ. feed-forward; в которых связи не образуют циклов) с одним скрытым слоем может аппроксимировать любую непрерывную функцию многих переменных с любой точностью, при условии, что сеть имеет достаточное количество нейронов в скрытом слое n .

Почему сети работают?

Theorem (Universal Approximation Theorem FFNN, George Cybenko, 1989)

Искусственная нейронная сеть прямой связи (англ. feed-forward; в которых связи не образуют циклов) с одним скрытым слоем может аппроксимировать любую непрерывную функцию многих переменных с любой точностью, при условии, что сеть имеет достаточное количество нейронов в скрытом слое n .

Theorem (Universal Approximation Theorem RNN)

Любая нелинейная динамическая система может быть аппроксимирована с любой точностью рекуррентной нейронной сетью, без ограничений на компактность пространства состояний системы, при условии, что сеть имеет достаточное количество нейронов в скрытом слое n .

- Автономные ОДУ, [Funahashi & Nakamura \(1993\)](#):

$$\dot{s} = g(s), \quad s(t=0) \in S_0.$$

- Неавтономные ОДУ, [Chow & Li \(2000\)](#):

$$\dot{s} = g(s) + f(t), \quad s(t=0) \in S_0.$$

- Примеры моделирования, ArXiv: [1512.05702](#).

Почему сети работают?

Theorem (Universal Approximation Theorem FFNN, George Cybenko, 1989)

Искусственная нейронная сеть прямой связи (англ. feed-forward; в которых связи не образуют циклов) с одним скрытым слоем может аппроксимировать любую непрерывную функцию многих переменных с любой точностью, при условии, что сеть имеет достаточное количество нейронов в скрытом слое n .

Theorem (Universal Approximation Theorem RNN)

Любая нелинейная динамическая система может быть аппроксимирована с любой точностью рекуррентной нейронной сетью, без ограничений на компактность пространства состояний системы, при условии, что сеть имеет достаточное количество нейронов в скрытом слое n .

Theorem (Turing machines Theorem RNN, Siegelmann & Sontag, 1991)

Любые машины Тьюринга могут моделироваться полностью связанными рекуррентными сетями, созданными из нейронов с сигмоидальными функциями активации, при условии, что сеть имеет достаточное количество нейронов в скрытом слое n и достаточное число шагов временной памяти K .

Содержание раздела

- ❶ Общие положения
 - Обзор мировых тенденций
 - Глубокое обучение
- ❷ Теоретические исследования ИПУ РАН
 - Направления
 - Синхронизация хаоса
 - Бифуркации дискретных отображений
- ❸ Примеры прикладных работ ИПУ РАН
 - Система распознавания вторжений в «Облако»
 - Обнаружение подвижных подводных объектов
 - Защита магистрального трубопровода
- ❹ Заключение

Тематика исследований

Тематика **Вычислительного интеллекта** предполагает конвергенцию двух основных направлений исследований:

- Нелинейная динамика – как основа для оценивания сложных динамических процессов и идентификации сложных динамических систем.
- Машинное обучение – как основа для анализа больших массивов слабоструктурированных данных и порождения над ними моделей, имеющих описательную, объяснительную и предсказательную силу.

При этом **взаимопроникновение** двух дисциплин ещё более сильное:

- Решение отдельных, как правило прикладных, задач нелинейной динамики при помощи нейронных сетей (принимая во внимание универсальную теорему об аппроксимации RNN).
- Применение методов нелинейной динамики в проектировании, обучении и исследовании глубоких нейронных сетей (принимая во внимание нелинейную природу ГНС).

О задаче

Синхронизация хаотических колебаний принадлежит к числу фундаментальных понятий теории нелинейной динамики и теории хаоса. Этот феномен широко распространён в природе, науке, технике и в обществе.

Виды синхронизации хаоса: обобщённая, полная, противофазная, с запаздыванием, частотная, фазовая, синхронизация временных масштабов.

Структура синхронизма систем: перемежаемость¹ между синхронным и несинхронным поведением элементов систем несёт важную информацию о свойствах их динамики.

Временная структура синхронизма систем – актуальная, но слабо изученная область.


¹С физической точки зрения перемежаемость вообще означает появление неких структур различного масштаба в среде (например вихрей, локализованных деформаций, температурных неоднородностей), которая исходно могла быть совершенно бесструктурной на этих масштабах. С математической точки зрения такое поведение характеризуется наличием редких, но сильных пиков в поведении индикатора структуры – некоей случайной величины

Определение Т-синхронизации

Определим исходное отображение:

$$\left\{ \mathbf{s}_{k-1}^{(n)}, \mathbf{s}_k^{(n)}, \mathbf{s}_{k+1}^{(n)} \right\} \Rightarrow T_k^{\alpha\varphi}|_n, \quad T_k^{\alpha\varphi} = [T_k^{\alpha\varphi}|_1, \dots, T_k^{\alpha\varphi}|_N].$$

$$T_o^{\alpha\varphi} = \{T0, T1, T2, T3N, T3P, T4N, T4P, T5N, T5P, \\ T6S, T6, T6L, T7S, T7, T7L, T8N, T8P\}.$$



Будем считать динамические системы синхронными в момент времени k , в смысле Т-синхронизации, если выполняется условие $J_k=1$:

$$J_k = \begin{cases} 1 & T_k^{\alpha\varphi}|_1 = \dots = T_k^{\alpha\varphi}|_n = \dots = T_k^{\alpha\varphi}|_N, \\ 0 & \text{иначе.} \end{cases}$$


Временная структура синхронизма

Theorem

Индикаторная последовательность

$$\{D_r^{SS}\}_{r=1}^{R^{SS}}, \quad D^{SS} \in \mathbb{Z}_2 = \{\bar{SD} = 0, SD = 1\}$$

является необходимым и достаточным условием описания временной структуры T-синхронизации, и позволяет проводить согласованное рассмотрение десинхронных $\bar{SD}$ и синхронных SD доменов.



Временная структура синхронизма

Theorem

Индикаторная последовательность

$$\{D_r^{SS}\}_{r=1}^{R^{SS}}, \quad D^{SS} \in \mathbb{Z}_2 = \{\bar{SD} = 0, SD = 1\}$$

является необходимым и достаточным условием описания временной структуры T-синхронизации, и позволяет проводить согласованное рассмотрение десинхронных $\bar{SD}$ и синхронных SD доменов.

a

Применение в нейросетевой области

- Анализ синхронности сложных взаимосвязанных динамических систем (структур) и/или процессов с целью формирования субоптимальных первичных информативных признаков.
- Исследование временной структуры синхронизма внутренних рекуррентных слоёв с целью повышения качества функционирования и/или улучшения обучаемости сети.



Выводы

- Т-синхронизация обобщает ряд известных типов синхронизации.
- Метод применим для исследования многомерных решёток с произвольной топологией.
- Подход применим для анализа экспериментальных данных.
- Анализатор инвариантен к сдвигам и растяжениям фазовых траекторий.
- Т-синхронизация позволяет исследовать в замкнутой форме временную структуру синхронизма хаотических систем.



A.V. Makarenko, The Study of Discrete Mappings in TQ-Space. Basic Principles. //Journal of Math. Sci., 2016, Vol. 219, Issue 2, pp. 190-203.
//Journal of Math. Sci., 2016, Vol. 219, Issue 2, pp. 190-203.



A.V. Makarenko, Analysis of the time structure of synchronization in multidimensional chaotic systems // Journal of Experimental and Theoretical Physics, 2015, Vol. 120, Issue 5, pp. 912-921.



A.V. Makarenko, Analysis of phase synchronization of chaotic oscillations in terms of symbolic CTQ-analysis // Technical Physics, 2016, Vol. 61, Issue 2, pp. 265-273.

О задаче

Введём в рассмотрение динамическую систему:

$$\mathbf{s}_{k+1} = \mathbf{f}(\mathbf{s}_k, \mathbf{p}), \quad \phi_{\mathbf{p}} : S \times K \rightarrow S, \quad \phi_{\mathbf{p}}(\mathbf{s}, k) \equiv \mathbf{f}^k(\mathbf{s}, \mathbf{p}),$$

со свойствами:

$$\mathbf{s} \in S \subset \mathbb{R}^N, \quad \mathbf{p} \in P \subset \mathbb{R}^L, \quad \mathbf{f} \in C^0(S \times P), \quad k \in K \subseteq \mathbb{Z}, \quad n \in \overline{1, N}, \quad l \in \overline{1, L},$$

Концепция бифуркаций в динамических системах впервые была выдвинута А. Пуанкаре для описания «расщепления» равновесных решений в семействе обыкновенных дифференциальных уравнений.

Второй этап исследования бифуркаций [А.А. Адронов и др.] заключался в основном в исследовании д.с. в аспекте изменения качественной структуры их орбит в результате малых возмущений системы, в связи с широким распространением прикладных задач для теории динамических систем и нелинейных колебаний.

Современная теория бифуркаций [В.И. Арнольд, Л.П. Шильников и др.] рассматривает не только бифуркации положений равновесия и предельных циклов, но перестройки системы в целом и, прежде всего, её инвариантных множеств, аттракторов.

Определение TQ-бифуркаций

Сгруппируем последовательные итерации отображения:

$$\{s, f(s, p), f^2(s, p)\} \rightarrow \{f(s, p), f^2(s, p), f^3(s, p)\},$$

TQ-бифуркацию в отображении определим как изменение набора T- и Q-символов в области варьирования переменной состояния s , отвечающее условию:

$$\langle T^{\alpha\varphi}, Q^{\alpha\varphi} \rangle_a^O \xrightarrow[p=p_b]{\text{TQ-bif}} \langle T^{\alpha\varphi}, Q^{\alpha\varphi} \rangle_b^O, \quad \langle T^{\alpha\varphi}, Q^{\alpha\varphi} \rangle_a^O \neq \langle T^{\alpha\varphi}, Q^{\alpha\varphi} \rangle_b^O, \quad p_a \neq p_b.$$

Theorem

TQ-бифуркации в дискретных отображениях подразделяются на три фундаментальных рода:

I – изменяется набор символов $T^{\alpha\varphi}$, набор символов $Q^{\alpha\varphi}$ – переходов между неизменными символами $T^{\alpha\varphi}$ остаётся неизменным.

II – набор символов $T^{\alpha\varphi}$ остаётся постоянным, но изменяется набор символов $Q^{\alpha\varphi}$.

III – изменяется как набор символов $T^{\alpha\varphi}$, так и набор символов $Q^{\alpha\varphi}$ – переходов между неизменными символами $T^{\alpha\varphi}$.


Определение ТQ-бифуркаций

Сгруппируем последовательные итерации отображения:

$$\{s, f(s, p), f^2(s, p)\} \rightarrow \{f(s, p), f^2(s, p), f^3(s, p)\},$$

ТQ-бифуркацию в отображении определим как изменение набора Т- и Q-символов в области варьирования переменной состояния s , отвечающее условию:

$$\langle T^{\alpha\varphi}, Q^{\alpha\varphi} \rangle_a^O \xrightarrow[p=p_b]{\text{TQ-bif}} \langle T^{\alpha\varphi}, Q^{\alpha\varphi} \rangle_b^O, \quad \langle T^{\alpha\varphi}, Q^{\alpha\varphi} \rangle_a^O \neq \langle T^{\alpha\varphi}, Q^{\alpha\varphi} \rangle_b^O, \quad p_a \neq p_b.$$



Определение ТQ-бифуркаций

Сгруппируем последовательные итерации отображения:

$$\{s, f(s, p), f^2(s, p)\} \rightarrow \{f(s, p), f^2(s, p), f^3(s, p)\},$$

ТQ-бифуркацию в отображении определим как изменение набора Т- и Q-символов в области варьирования переменной состояния s , отвечающее условию:

$$\langle T^{\alpha\varphi}, Q^{\alpha\varphi} \rangle_a^O \xrightarrow[p=p_b]{\text{TQ-bif}} \langle T^{\alpha\varphi}, Q^{\alpha\varphi} \rangle_b^O, \quad \langle T^{\alpha\varphi}, Q^{\alpha\varphi} \rangle_a^O \neq \langle T^{\alpha\varphi}, Q^{\alpha\varphi} \rangle_b^O, \quad p_a \neq p_b.$$

Применение в нейросетевой области

- Анализ перестроений аттракторов динамических систем и/или формы траекторий процессов с целью формирования субоптимальных первичных информативных признаков.
- Исследование перестроений аттракторов рекуррентных слоёв с целью повышения качества функционирования и/или улучшения обучаемости сети.

Выводы

- ТQ-бифуркации связаны с качественным изменением формы траекторий отображений в расширенном пространстве состояний.
- ТQ-бифуркации позволяют исследовать ряд феноменов: синхронизация, самоорганизация, управление (подавление) хаосом.
- Метод применим для исследования многомерных решёток с произвольной топологией:
 - магнитные решётки – качественные свойства пространственного профиля намагниченности кристалла;
 - кристаллические решётки – динамика заряженных частиц высоких энергий в изогнутых кристаллах.
- Анализатор инвариантен к сдвигам и растяжениям фазовых траекторий.



A.V. Makarenko, The Study of Discrete Mappings in TQ-Space. Basic Principles. //Journal of Math. Sci., 2016, Vol. 219, Issue 2, pp. 190-203.
//Journal of Math. Sci., 2016, Vol. 219, Issue 2, pp. 190-203.




A.V. Makarenko, TQ-bifurcations in discrete dynamical systems: Analysis of qualitative rearrangements of the oscillation mode // Journal of Experimental and Theoretical Physics, 2016, Vol. 123, Issue 4, pp. 666-676.

Содержание раздела


- ❶ Общие положения
 - Обзор мировых тенденций
 - Глубокое обучение
- ❷ Теоретические исследования ИПУ РАН
 - Направления
 - Синхронизация хаоса
 - Бифуркации дискретных отображений
- ❸ Примеры прикладных работ ИПУ РАН
 - Система распознавания вторжений в «Облако»
 - Обнаружение подвижных подводных объектов
 - Защита магистрального трубопровода
- ❹ Заключение

О задаче: Система распознавания вторжений в «Облако»



- Крупная вычислительная система;
- Предоставление «сырых» виртуальных машин;
- Обнаружение пассивных и активных атак;
- Выявление: доступа к информации / уничтожение системы;
- Внешние и внутренние атаки.

Контур обработки целевой информации



- Перекрёстный анализ метаданных.
- Поведенческий мониторинг.
- Информация из внешних источников.

Результаты



- Выявление нетипичного поведения пользователей;
- Выявление нетипичной активности узлов системы;
- Обнаружение пассивных и активных атак;
- Предсказание цели и назначения атак.

О задаче: Обнаружение подвижных подводных объектов



Источник: <https://www.youtube.com/watch?v=QqFIZblQJ1c>

- Разработка системы подводного видения;
- Задача обнаружение рыбы в водоёмах рыбных ферм;
- Сегментация и выделение контура объекта.


Решение и результаты

Простое обнаружение/классификация



Fish: True, Conf.: 0.9992


Детектирование



b1. Fish: True, Conf.: 0.9864, Pos.: 0.9452

b2. Fish: True, Conf.: 0.9137, Pos.: 0.8426

Сегментирование экземпляров



c1. Pos.: 0.8846, Compl.: 0.53

c2. Pos.: 0.7921, Compl.: 0.33

Примечания:

- Классификатор может строиться как одноклассовый, либо как многоклассовый.
- Сеть инвариантна к размеру входного изображения и размерам объектов.
- Затраты времени на отработку алгоритмов (GPU NVIDIA Geforce 1080): 12 мс, 27 мс, 194 мс.
- В случае решения задачи «Выделение контура» на выходе сети используется полиномиальный аппроксиматор полигонов.
- Решение интегрировано в серийное изделие для подсчёта рыб и управления лазерной системой биоочистки рыбы.


О задаче: Защита магистрального трубопровода




- 0 – Фон;
- 1 – Утечка;
- 2 – Лопата;
- 3 – Экскаватор;
- 4 – Сверление;
- 5 – Сварка;
- 6 – Шлифовка.

- Трубопроводы ПАО «Транснефть»;
- Общая протяжённость МТ – свыше 60 тысяч км;
- Обнаружение протечек;
- Выявление хищений;
- Антитеррористические мероприятия.

О задаче: Защита магистрального трубопровода




- 0 – Фон;
- 1 – Утечка;
- 2 – Лопата;
- 3 – Экскаватор;
- 4 – Сверление;
- 5 – Сварка;
- 6 – Шлифовка.




Когерентный волоконно-оптический рефлектометр, функционирующий на основе рассеивания Релея.

О задаче: Защита магистрального трубопровода




- 0 – Фон;
- 1 – Утечка;
- 2 – Лопата;
- 3 – Экскаватор;
- 4 – Сверление;
- 5 – Сварка;
- 6 – Шлифовка.




Когерентная рефлектограмма обладает высокой чувствительностью к механическим воздействиям на волокно (обнаруживаются «шевеления» от 70 нм).

О задаче: Защита магистрального трубопровода



- 0 – Фон;
- 1 – Утечка;
- 2 – Лопата;
- 3 – Экскаватор;
- 4 – Сверление;
- 5 – Сварка;
- 6 – Шлифовка.



Анализ время-частотных портретов сигналов позволяет регистрировать и распознавать события происходящие в зоне заложения ВОК.

О задаче: Защита магистрального трубопровода




- 0 – Фон;
 - 1 – Утечка;
 - 2 – Лопата;
 - 3 – Экскаватор;
 - 4 – Сверление;
 - 5 – Сварка;
 - 6 – Шлифовка.
-
- 3 географически разнесённых трубопровода;
 - 14 месяцев активных экспериментов;
 - 56 помеховых подклассов;
 - 70 ТБ «сырых» данных.

Основные проблемы

- Паразитные модуляции рефлектограммы.
- Локальные участки временной нечувствительности сенсора.
- Существенное изменение отношения сигнал/шум по длине сенсора.
- Рефлектометр теряет информацию о направлении деформации волокна.
- Большое разнообразие и нестационарность сигнальных портретов.
- Интенсивные сигнало-подобные помехи.
- Существенная вариативность структурных характеристик сигналов.

Первичный классификатор сигналов

В классификаторе центральное место занимает глубокая нейронная сеть:



A.V. Makarenko, Deep Learning Algorithms for Signal Recognition in Long Perimeter Monitoring Distributed Fiber Optic Sensors. // The IEEE International Workshop MLSP 2016 / Proceedings – Vietri sul Mare, IIASS, 2016.

Результаты

Получено высокое качество обнаружения и распознавания полезных сигналов:

Таблица : Классификатор C1: матрица ошибок, тестовое множество.

Event class		Предсказания, %						
		0	1	2	3	4	5	6
Reference, 100%	0	91.80	3.96	0.64	0.14	2.34	0.42	0.70
	1	13.78	79.24	5.38	0.02	1.14	0.28	0.16
	2	4.24	3.34	91.30	0.14	0.66	0.00	0.32
	3	2.36	0.10	0.28	97.08	0.12	0.00	0.06
	4	8.68	0.38	0.22	0.00	89.80	0.28	0.64
	5	3.34	0.14	0.02	0.00	0.30	94.40	1.80
	6	3.42	0.12	0.14	0.00	0.70	0.82	94.80
Prec.		71.93	90.79	93.18	99.69	94.47	98.13	96.26
F1 sc.		80.66	84.62	92.23	98.37	92.07	96.23	95.53

- Предыдущие решения (по утечке) давали менее 45% правильно распознанных блоков данных;
- Система внедрена на реальном нефтепроводе и контролирует участок протяжённостью свыше 2 500 км;

Содержание раздела

- ❶ Общие положения
 - Обзор мировых тенденций
 - Глубокое обучение
- ❷ Теоретические исследования ИПУ РАН
 - Направления
 - Синхронизация хаоса
 - Бифуркации дискретных отображений
- ❸ Примеры прикладных работ ИПУ РАН
 - Система распознавания вторжений в «Облако»
 - Обнаружение подвижных подводных объектов
 - Защита магистрального трубопровода
- ❹ Заключение

Текущие исследования

Нелинейная динамика

- Исследование дихотомического подразделения TQ-пространства с целью оценивания топологической энтропии дискретных динамических систем и управления хаотическими колебаниями.

Нейронные сети

- Разработка и исследование конструктивных нейросетевых подходов к решению нелинейных обратных задач.
- Синтез глубоких нейронных сетей специальной архитектуры со стабилизированным уровнем ошибок второго рода.
- Разработка методов анализа обученных глубоких нейронных сетей с целью извлечения из них «выученных знаний».

Благодарю за внимание!