

ИНТЕЛЛЕКТУАЛЬНЫЕ ИЗМЕРИТЕЛЬНЫЕ СИСТЕМЫ: ИНФОРМАЦИОННО-АНАЛИТИЧЕСКИЙ ПОДХОД К ТЕОРИИ САМООРГАНИЗАЦИИ АДАПТИВНЫХ МОДЕЛЕЙ ОБРАБОТКИ ДАННЫХ

INTELLIGENT MEASUREMENT SYSTEMS: INFORMATION –ANALITICAL APPROACH TO SELF-ORGANISATION MODEL OF ADAPTIVE DATA ANALYSIS

Санкт-Петербург, СПбГТУ
SaintPetersburg, SPbSTU

Формулируется информационно-аналитический подход к задаче синтеза адаптивных самоорганизующихся нейронных сетей, ориентированных на оптимальное извлечение информации из данных. Рассматриваются информационные критерии обучения как задачи оптимизации вычислительных структур. Акцентируется внимание на эффективности кумулянтного анализа случайных негауссовых процессов и их преобразований.

1. Введение.

Интеллектуальные измерительные системы (ИНИС) - быстро развивающийся класс систем автоматизации физического эксперимента, использующих нестандартные алгоритмические решения для получения, обработки и интерпретации экспериментальных данных, формирование выводов и заключений, основанных на знаниях. Обзор современной литературы отражает многообразие определений и подходов к понятию ИНИС, их назначению, решаемым задачам [1]. Однако несмотря на обилие подходов и задач, рассматриваемых в данной области, очевиден недостаток внимания к решению основной проблемы – теории организации эксперимента и принципам извлечения полезной информации из данных.

Анализ проблемы показывает, что большинство предлагаемых подходов к обработке информации в основном базируется на традиционных вычислительных моделях, реализующих прямые классические методы. Однако такие методы имеют ограниченные возможности, в частности, при решении плохо формализуемых, некорректных, условно корректных, или задач эволюционного типа, требующих привлечения нестандартного математического аппарата. Примерами подобных задач являются плохо структурированные алгоритмы нечеткой логики, мягких вычислений и измерений, статистических решений в условиях априорной неопределенности, распознавание образов и сцен, принятие решений на основе ограниченной или неопределенной априорной информации, контекстно-зависимый семантический анализ текстовой информации, ряд других задач. Сопоставление методов решения подобных задач показывает, что в конечном итоге интеллектуальная обработка данных часто сводится к необходимости решения наиболее общей задачи – выбору одной из набора возможных гипотез о модели изучаемого объекта или явления и оцениванию параметров этой модели. Особую роль здесь приобретает сочетание ключевых функций измерения и обработки данных, объединяемых понятием **измерительно-вычислительный эксперимент (ИВЭ)**. Анализ концепции ИВЭ с позиции интеллектуальных измерений позволяет оценить перспективу и потенциальные возможности совершенствования ИНИС.

2. Формулировка проблемы.

Формулируется обобщенная задача физического эксперимента как проблема выбора гипотезы $H(m)_i$ из множества $\mathbf{H} \equiv \{H(m)_i\}$ о классе модели m_i , формируемой в результате измерительно-вычислительного эксперимента, в процессе последовательного анализа решений на множестве $\mathbf{X} \equiv \{\mathbf{x}_i, i = 1, n\}$ экспериментальных данных $\mathbf{x}_1, \mathbf{x}_2, \dots$. Уточняющими условиями являются ограничения на класс исходных данных - параметров, представленный линейной моделью в $\mathbf{X} \in \mathbf{R}^N$ последовательности векторных переменных $\mathbf{x}_i = [\mathbf{x}_{i1}, \mathbf{x}_{i2}, \dots, \mathbf{x}_{in}]^T$, (T - символ транспонирования). Задача сводится к поиску оптимального в смысле количества информации, функционально-логического преобразования оператором $\mathbf{F}$, квантующим векторное пространство параметров $\mathbf{X} \in \mathbf{R}^N$ на ограниченное множество k классов $m_1, m_2, \dots, m_k$, и последующего принятия соответствующей гипотезы о классе модели.

Принципиальным подходом к решению подобного класса плохо формализуемых нестандартных задач является парадигма рекуррентных моделей адаптивной самоорганизации, реализованная, в частности, в современной теории искусственных нейронных сетей [2]. Ключевые положения данной теории – принципы **коннекционизма** и тренировки или обучения среды,

основанных на данных - позволяют сформировать новые подходы и методы построения эффективных моделей вычислителей.

С математической точки зрения парадигма рекуррентных моделей адаптивной самоорганизации – это парадигма самоорганизующейся вычислительной среды, тренируемой или обучаемой решению широкого класса логико-алгебраических задач. Частный случай такой среды – классическая архитектура искусственных нейронных сетей, реагирующих на предъявляемый ее n входам многомерный векторный сигнал-образ $x = [x_1, x_2, \dots, x_n]^T$, в результате чего на выходе формируется информационное сообщение о классе воспринимаемого сигнала. Более общей моделью следует признать самоорганизующуюся нейронную сеть, функционирующую в **обобщенном нейро-логическом базисе** и формирующую логико-семантическую модель знаний.

3. Рекуррентные модели адаптивной самоорганизации.

В алгебраической интерпретации работа обобщенной нейронной сети начинается с восприятия входного векторного сигнала, являющегося элементом n -мерного векторного пространства

$x \in R^n$, а промежуточной реакцией сети на предъявленный входной образ является сформированный на ее m выходах m -мерный выходной отклик $f = [f_1, f_2, \dots, f_m]^T$, каждая компонента которого соответствует состоянию одного из выходных нейронов. Учитывая, что выходной вектор является элементом m -мерного векторного пространства $f \in R^m$, алгоритм преобразования можно трактовать в общем случае как нелинейное векторное отображение множества $X \in R^n$ исходных данных $\{x^{(1)}, x^{(2)}, \dots, x^{(s)}\}$ в множество образов $\{f^{(1)}, f^{(2)}, \dots, f^{(s)}\}$ оператором

$$F : R^n \Rightarrow R^m, \\ x \mapsto f = \varphi(W, X),$$

вид которого задается значениями соответствующих синаптических весов w_{ij} матрицы параметров $W = [w_{ij}]$, настраиваемых в процессе обучения сети, и характером функции активации $\varphi(\cdot)$. Введение алгебры логических выводов в оператор F позволяет перейти к обобщенным продукционным моделям знаний, решающим общую задачу интеллектуализации физического эксперимента.

Ключевой этап формирования модели - определение целевой функции обучения сети на класс задач, задающей формальный критерий качества. Очевидной целевой функцией в данной постановке является максимальное извлечение количества информации из экспериментальных данных. Решение организуется как последовательный поиск на множестве $X \in R^n$ векторных переменных $x_1, x_2, \dots$ ограниченного множества k классов $m_1, m_2, \dots, m_k$, квантующих векторное пространство через оператор отображения $F(1)$.

Обучение сети - процесс целенаправленного изменения параметров матрицы синаптических связей W таким образом, чтобы реакция обученной сети наилучшим образом соответствовала желаемому целевому вектору $f_{эт} = [f_{эт1}, f_{эт2}, \dots, f_{этm}]^T$ с компонентами $f_{этj}$, задающими требуемое состояние каждого j -го выходного нейрона. Формируемая при этом целевая функция минимизации невязки представляет критерий качества настройки. Если при этом заданы множество обучающих параметров $\{x^{(1)}, x^{(2)}, \dots, x^{(s)}\}$ и способ вычисления суммарной оценки качества, то задача обучения формулируется как классическая задача многомерной оптимизации, в общем случае – невыпуклой, т. е. имеющей сложную поверхность со многими локальными и глобальным минимумами. В формальной постановке ее можно записать в форме критерия максимизации

$$W_{opt} : J(\phi(f, W)) \Rightarrow \max, \\ W \in W$$

где: $J(\cdot)$ – функционал, определяющий некоторую норму целевой функции количества информации $\phi(f, W)$, вырабатываемой нейропроцессором на своих выходах $f \in R^m$, при оптимальном значении матрицы синаптических связей W_{opt} , определяемой на заданном множестве $W \in W^{M \times N}$.

С учетом информационной модели в качестве формальной оценки целевой функции количества информации может быть выбрана взаимная информация $I(f, x)$, формируемая на выходах нейропроцессора относительно своих входов:

$$\phi(f, W) \cong I(f, x).$$

Стандартным решением задачи оптимизации в условиях неопределенности целевой функции $J(I(\mathbf{f}, \mathbf{x}))$ являются методы градиентного поиска экстремумов согласно итерационной процедуре:

$$\mathbf{W}[k+1] = \mathbf{W}[k] + \mu \nabla \phi(\mathbf{f}, \mathbf{W})$$

где: $\nabla \phi(\mathbf{f}, \mathbf{W})$ - градиент целевой функции $\phi(\mathbf{f}, \mathbf{W})$, определяющий стратегию поиска экстремума целевой функции оптимизации, μ - скорость движения в выбранном направлении.

В то же время большинство используемых критериев носят частный характер, не отражающий особенности оптимальности извлечения информации из данных. В этом плане наиболее эффективной представляется формулировка оптимизационной задачи построения рекуррентных моделей адаптивных вычислителей на основе информационно-аналитического критерия самоорганизации.

4. Информационно-аналитическая модель ИНС.

Информационно-аналитический подход приводит к вероятностной модели нейропроцессора, описывающей реакцию нейронной сети в терминах информационно-статистических характеристик. Для этого введем обобщенную рекуррентную модель вычислителя, которую можно представить как преобразование входной векторной случайной величины $\mathbf{x}(t) = [x_1(t), x_2(t), \dots, x_n(t)]^T$ в выходную $\mathbf{f}(t) = [f_1(t), f_2(t), \dots, f_n(t)]^T$, с плотностью вероятности:

$$p_f(\mathbf{f}) = \frac{1}{|\det \Phi(\mathbf{W}\mathbf{x})|} p_x(\mathbf{x}),$$

где: $|\det \Phi(\mathbf{W}\mathbf{x})|$ - модуль функционального определителя (якобиана) матрицы преобразования сети,

$$\det \Phi(\mathbf{W}\mathbf{x}) = \det \left[\frac{\partial f_i}{\partial y_i} \right].$$

Количественной оценкой эффективности описанной модели является количество взаимной информации $I(\mathbf{x}; \mathbf{f})$, содержащейся в выходном векторе $\mathbf{f}(t) = [f_1(t), f_2(t), \dots, f_n(t)]^T$ относительно входного $\mathbf{x}(t) = [x_1(t), x_2(t), \dots, x_n(t)]^T$. Оценка имеет вид

$$I(\mathbf{f}; \mathbf{x}) = H(\mathbf{f}) - H(\mathbf{f}|\mathbf{x}),$$

и характеризует изменение неопределенности исходного векторного процесса $\mathbf{x}(t)$ в результате получения информации о распределении отдельных компонент, входящих в первоначальное многомерное распределение, где $H(\mathbf{f}|\mathbf{x})$ - условная энтропия выходного вектора, характеризующая оставшуюся неопределенность из-за «не извлеченной» информации из входного сигнала $\mathbf{x}$. При информационном подходе мерой эффективности оценивания случайной величины, распределенной с плотностью вероятности $p(\mathbf{x})$, является кросс-энтропия, или энтропия Кульбака–Лейблера (Kullback–Leibler), иногда называемая дивергенцией Кульбака–Лейблера:

$$D(p||p^*) = \int p(\mathbf{x}) \log \frac{p(\mathbf{x})}{p^*(\mathbf{x})} d\mathbf{x},$$

связывающая вероятность $p(\mathbf{x})$ с ее оценкой $p^*(\mathbf{x})$. Особенность данной характеристики – ее положительное значение $D(p||p^*) \geq 0$, что является следствием очевидного неравенства

$$\int p(\mathbf{x}) \log p(\mathbf{x}) d\mathbf{x} \geq \int p(\mathbf{x}) \log p^*(\mathbf{x}) d\mathbf{x}.$$

Применяя соответствующие преобразования информационных критериев, можно получить окончательный вид обучающего правила по информационному критерию:

$$\mathbf{W}[k+1] = \mathbf{W}[k] + \mu (\mathbf{I} - \psi(\mathbf{y}[k])\mathbf{y}^T[k])\mathbf{W}[k],$$

где: $\psi(y)$ - вектор градиента, аппроксимирующий стратегию поиска оптимума при неизвестной функции плотности вероятности $p(y)$, I - единичная матрица.

Полученное выражение отражает идею максимизации информации о распознаваемых классах переменных входного множества X через поиск оптимизирующей матрицы синаптических связей W_{opt} , «развязывающей» статистически-независимые переменные по величине взаимной информации. Это является основой создания высокоэффективных рекуррентных моделей адаптивного самоорганизующегося вычислителя на основе обобщенного информационно-аналитического критерия анализа данных.

Оценка количества информации в выходе нейронной сети, представленная уравнением $I(f; x) = H(f) - H(f|x)$, достигает максимума в момент достижения нейронной сети своей оптимальной производительности. При этом выход нейропроцессора содержит максимальное количество информации о входных данных. В случае, когда НС не вносит дополнительной информации в входные данные, такой как шум или иные зависимости не относящиеся к входным данным, оценку информации выхода можно записать в виде $I(f; x) = H(f)$. Таким образом, цель обучения НС можно представить как оптимизацию функции энтропии выхода с целью ее увеличения. Можно отметить, что максимум энтропии дискретная ограниченная величина достигает в случае равномерного распределения. Исходя из этого факта, следующего из определения энтропии дискретной величины, следует, что нелинейная функция активации нейронов должна быть непрерывной, дифференцируемой, и связана с функцией плотности распределения независимой

случайной величины $p(s)$ следующим соотношением: $p(s) = \left| \frac{\partial f}{\partial y} \right|$ что позволяет НС учитывать информацию о функции распределения независимой величины, находящуюся в статистиках высоких порядков.

В качестве оценки независимости элементов выходного вектора НС может быть использована другая информационная мера, например взаимная информация. Взаимная информация выходных элементов может быть представлена в виде: $I(f_1, \dots, f_n) = H(f_1) + \dots + H(f_n) - H(f_1, \dots, f_n)$, где $H(f_1, \dots, f_n)$ - совместная энтропия выхода. Поскольку взаимная информация величина положительная, то ее нулевое значение достигается только когда совместная энтропия равна сумме маргинальных энтропий выходов НС. Используя понятие взаимной информации, можно сформулировать цель обучения как минимизация взаимной информации между элементами выходного вектора. Независимость элементов выходного вектора можно записать через расхождение Кульбака-Лейблера, которое для взаимной информации между переменными f_1 и f_2 запишется в виде расстояния между совместной функцией плотности распределения выходного вектора и произведений соответствующих функций его компонент:

$$I(f_1, f_2) = KL(p(f_1, f_2), p(f_1)p(f_2)) = \iint p(f_1, f_2) \log \frac{p(f_1, f_2)}{p(f_1)p(f_2)} df_1 df_2, \text{ эта мера расстояния}$$

между распределениями равна нулю, только в случае полной статистической независимости f_1 и f_2 . Таким образом, можно выделить два информационно-аналитических критерия обучения НС, которые приводят к решению поставленной задачи: максимизация энтропии выхода и минимизация взаимной информации между элементами выходного вектора НС.

5. Применение статистик высших порядков.

Полученные информационно-аналитические критерии самоорганизации базируются на оценивании информационных характеристик через определение классических вероятностных характеристик- моментов и плотности распределения вероятностей исследуемых величин. Вместе с тем существует более эффективный аппарат экспериментального статистического анализа с помощью кумулянтов (семиинварантов) и кумулянтных функций, являющихся нелинейными комбинациями статистик высших порядков []. И хотя с формальной точки зрения кумулянтное описание случайных статистик дает столь же полное описание их представления, что и моментное, они обладают целым рядом важных преимуществ для решения рассмотренного класса прикладных задач:

- четко выраженный самостоятельный статистический смысл и определенная степень независимо друг от друга при задании модели,
- широкие возможности в детальном описании различной степени негауссовости случайной величины,
- хорошая аппроксимируемость вероятностных распределений различных классов.

Применение аппарата кумулянтного анализа позволяет перейти к более удобным адаптированным алгоритмам оперативного обучения НС, не требующим знания законов распределения анализируемых статистик.

В качестве иллюстрирующих примеров в докладе рассматриваются применения ИниС для решения задач технической диагностики механических конструкций, построения интеллектуальных охранных систем, задач медицинской диагностики.

Библиография.

1. S.Russel, P.Norvig. Artificial Intelligence – A Modern Approach. Printice Hall, 1995.
2. Хакен Г. Синергетика. Иерархия неустойчивостей в самоорганизующихся системах и устройствах. М., Мир, 1985.
3. Малахов А.Н. Кумулянтный анализ случайных негауссовых процессов и их преобразований. М., Изд. «Сов.радио», 1978.