



# Нейросети: возможности использования алгоритмов самообучения в системах управления теплоэнергопотреблением зданий

*Н. В. Шилкин, канд. техн. наук, профессор Московского архитектурного института, otvet@abok.ru*  
*М. М. Бродач, канд. техн. наук, профессор Московского архитектурного института*

**Ключевые слова:** нейросеть, алгоритм самообучения, математические модели теплового режима помещений, система управления теплоэнергопотреблением здания, идентификация

Современные системы управления теплоэнергопотреблением зданий позволяют обеспечить комфортные условия в помещении и снизить энергопотребление, однако это управление не является оптимальным: достижение максимальных показателей теплового комфорта при минимальных затратах энергетических ресурсов возможно лишь при решении оптимизационной задачи – задачи оптимального управления теплоэнергопотреблением зданий на основе математического моделирования [1, 2]. Наиболее высокое соответствие математической модели объекту управления может быть достигнуто за счет использования алгоритмов самообучения. Одной из возможностей реализации алгоритмов самообучения в системах управления теплоэнергопотреблением зданий является использование искусственных нейронных сетей (нейросетей).

## Особенности математических моделей теплового режима помещений, предназначенных для использования в системах управления

В монографии [3] отмечены два основных требования к математическим моделям теплового режима помещений, предназначенным для использования в системах управления (по сравнению с моделями, предназначенными для проектирования):

- необходимость высокой точности численного моделирования теплового режима,
- программные ограничения по объему и времени вычислений.

Противоречивость этих требований, но при этом и необходимость их одновременного выполнения требуют перехода от универсальной математической модели к специализированной (предназначенной для использования в системах управления) математической модели теплового режима.

Специализированная математическая модель теплового режима позволяет при сокращении объема вычислений не только не потерять точности моделирования, но даже повысить эту точность по сравнению с универсальной моделью за счет использования экспериментальных данных.

В [3] указаны основные направления перехода от универсальной модели к специализированной.

Исходным материалом для разработки является универсальная модель. Переход к специализированной модели осуществляется за счет «сужения» универсальной модели без потери, а желательно и с увеличением точности, по следующим направлениям:

- сокращение количества независимых переменных (в задаче проектирования – это исходные данные, в задаче управления – это входные параметры) путем перевода их в фиксированные параметры расчетной модели. Например, в модели для управления выпадают: группа данных, касающихся геометрических размеров помещений здания, группа данных, характеризующих размеры и теплофизические свойства ограждающих конструкций, и многие другие;
- совершенствование алгоритма вычислений в направлении сокращения времени вычислений и повышения точности результатов на основе конкретизации постановки задачи. Большая определенность постановки задачи в случае специализированной модели во многих случаях дает возможность использовать более эффективные вычислительные методы;
- повышение точности моделирования теплового режима за счет использования экспериментальных данных. Здесь очень много возможностей – от простого введения в расчет в качестве параметров характеристик, полученных при натурных измерениях в данном помещении, до уточнения в результате проведения измерений некоторых допущений в исходной модели. Например, в универсальной модели делается допущение о равномерности распределения проникающей солнечной радиации по внутренним поверхностям ограждающих конструкций по результатам измерений в конкретном помещении, накоплению статистики – это положение может быть уточнено. Большое значение имеет введение в расчетную модель уточненных данных, касающихся величин коэффициентов теплообмена на поверхности ограждений. По результатам измерений может быть в значительной мере повышена точность учета теплоаккумулирующей способности оборудования и мебели.

#### **Повышение адекватности математической модели управления тепловым режимом помещения**

Важным этапом разработки математической модели теплового режима помещения, предназначенной для использования в системах управления, является

Полная техническая информация:



[www.solerpalau.ru](http://www.solerpalau.ru)

**Soler&Palau**  
Ventilation Group

## Канальный вентилятор JETLINE

Новинка 2019



Реклама

**СВЕРХПРОИЗВОДИТЕЛЬНЫЙ  
СВЕРХКОМПАКТНЫЙ  
СВЕРХТИХИЙ**

- самые тихие и компактные в своем классе
- электродвигатель с виброизоляторами (гасит до 90% вибрации от мотора)
- крыльчатка нового поколения TURBOJET
- улучшенная аэродинамика
- высокая производительность и давление



вентиляция и кондиционирование

**БЛАГОВЕСТ**  
PRO.BLAGOVEST.RU

определение неизвестных или приближенно заданных параметров модели по данным, полученным в результате реального функционирования объекта, так называемая идентификация. Идентификация – экспериментальный метод конкретизации математической модели теплового режима помещения по входным и выходным сигналам объекта [3].

Повышение адекватности математической модели управления тепловым режимом помещения связано не только с идентификацией ее к теплотехническим особенностям помещения и технологического процесса в нем, но также с учетом реакции помещения на внешние климатические воздействия. В связи с тем что период повторяемости внешних климатических воздействий составляет годы, это создает большие трудности в задаче идентификации математической модели. Одним из путей решения этой задачи является использование самообучающейся математической модели [4, 5].

### Использование алгоритмов самообучения

Был предложен следующий алгоритм самообучения математических моделей управления теплоэнергопотреблением зданий [3].

В систему управления теплоэнергопотреблением дополнительно вводится программный блок-эмулятор показаний датчиков внешних метеоусловий, передающий смоделированные показания датчиков в программу обработки данных. В начальный период эксплуатации системы время между циклами управления используется для самообучения системы. На период между циклами управления обрабатываются сигналы не от реальных датчиков внешних метеоусловий, а смоделированные показания. Работа системы во время обучения происходит так же, как и во время процесса управления, с той лишь разницей, что входную информацию система получает от имитатора датчиков внешних метеоусловий, а выходную – передает программе, моделирующей формирование микроклимата. После того как на очередной математической модели формирования микроклимата обучение закончится, вводится более сложная математическая модель формирования микроклимата, и система, используя накопленный опыт, обучается на этой модели. Как только система начнет достаточно быстро переходить от одной математической модели формирования микроклимата к другой, процесс обучения на моделях заканчивается, и система переводится в режим обучения на

реальном объекте. Время обучения сокращается за счет того, что в период обучения на математических моделях частота циклов управления увеличивается на два порядка.

### Искусственные нейронные сети (нейросети)

Одним из вариантов реализации алгоритмов обучения, в том числе и самообучения – «обучения без учителя» (англ. *unsupervised learning*), является использование так называемых нейросетей – искусственных нейронных сетей (ИНС, англ. *artificial neural networks, ANN*).

**Искусственная нейронная сеть** – математическая модель, построенная на принципах действия биологических нейронных сетей.

Основной структурной единицей биологической нейронной сети является нейрон – узкоспециализированная нервная клетка. Нейрон может принимать информацию от другого нейрона или иного органа, обрабатывать ее, хранить и передавать далее, также другому нейрону или иному органу. Нейроны посредством разветвленных связей объединяются в биологические нейронные сети. Поскольку один нейрон может быть связан со многими другими нейронами (так, в человеческом мозге один нейрон может иметь связи с 20 тысячами других нейронов), а общее количество нейронов (и, соответственно, связей) в сети может быть очень большим, биологическая нейронная сеть, построенная на относительно простых нейронах, сама может быть очень сложной.

Подобно биологической нейронной сети, искусственная нейронная сеть строится на относительно простых элементах – искусственных нейронах. Искусственный нейрон получает входные сигналы, обрабатывает их по определенному алгоритму и в зависимости от результата обработки передает далее определенный выходной сигнал. Аналогично биологической нейронной сети, в искусственной нейронной сети один искусственный нейрон может быть связан со многими другими, в результате чего на относительно простых элементах и алгоритмах может быть реализована очень сложная сеть.

Преимущества искусственных нейронных сетей – относительно простая аппаратная реализация, но при этом потенциально очень высокое быстродействие, помехоустойчивость, отказоустойчивость. Но главное преимущество искусственных нейронных сетей перед традиционными алгоритмами – это возможность обучения. Искусственные нейронные сети не

программируются в традиционном понимании – они обучаются.

Основные задачи, которые решаются с использованием искусственных нейронных сетей, – это распознавание образов, управление в реальном времени, прогнозирование, оптимизация.

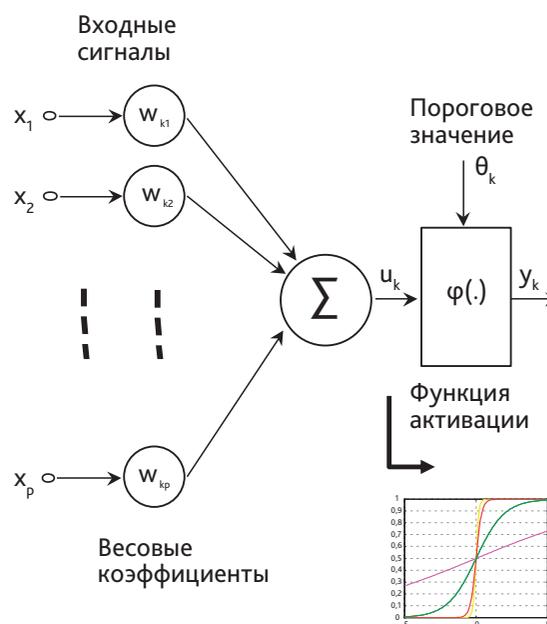
## Принцип работы искусственной нейронной сети

Схема искусственного нейрона приведена на рис. 1. Искусственный нейрон (англ. *artificial neuron*) – это упрощенная модель биологического нейрона. Имеется  $n$  входных сигналов  $X_1 \dots X_n$ , которые поступают от других нейронов и подаются на вход сумматора  $\Sigma$ . При этом сигнал от каждого нейрона имеет разную значимость, «вес» и, соответственно, может быть скорректирован введением своего рода поправочного коэффициента  $W_1 \dots W_n$  – «веса» каждого входного сигнала, весовых коэффициентов, то есть коэффициентов связи между нейронами.

Сигналы, скорректированные с учетом коэффициентов связи, суммируются и далее поступают в вычислитель передаточной функции (функции активации)  $\varphi$ . Вычислитель передаточной функции, в зависимости от заданного порогового значения  $\theta$ , вырабатывает тот или иной выходной сигнал  $Y$ , который и передается другим нейронам в качестве входного сигнала.

Схема искусственной нейронной сети приведена на рис. 2. Искусственные нейроны, обрабатывающие входные сигналы, составляют входной слой; искусственные нейроны, выдающие результирующие сигналы (результат работы нейросети), составляют, соответственно, выходной слой. Однако между входным и выходным слоями могут быть добавлены промежуточные скрытые слои со многими связями между различными нейронами, которые и выполняют основные вычислительные операции. В результате на простых элементах могут быть построены сети очень сложной архитектуры. К настоящему времени разработано множество типов архитектуры искусственных нейронных сетей.

Одно из главных преимуществ нейронных сетей перед традиционными алгоритмами – возможность обучения. С точки зрения математической модели обучения искусственной нейронной сети – это нахождение коэффициентов связей между нейронами. Именно значения коэффициентов связей между нейронами (весовых коэффициентов) и являются «знанием» искусственной нейронной сети.

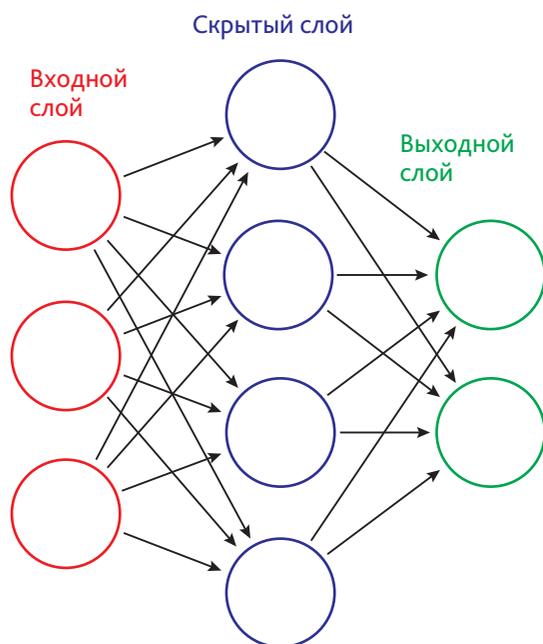


■ Рис. 1. Схема искусственного нейрона:  $X_1 \dots X_n$  – входные сигналы,  $W_1 \dots W_n$  – «вес» входных сигналов (весовые коэффициенты) – коэффициенты связи между нейронами,  $\Sigma$  – сумматор входных сигналов,  $\varphi$  – вычислитель передаточной функции (функции активации),  $\theta$  – пороговое значение,  $Y$  – выходной сигнал

В процессе обучения нейронная сеть способна выявлять сложные зависимости между входными данными и выходным результатом. При известных результатах реакции на входной сигнал появляется возможность корректировать весовые коэффициенты для уменьшения ошибки до тех пор, пока сеть не сможет вернуть верный результат.

## Пример практической реализации: NEUROBAT – самообучающийся контроллер управления отоплением на основе нейросетей

В качестве примера практической реализации алгоритмов самообучения на основе использования нейросетей может быть рассмотрен разработанный швейцарскими специалистами самообучающийся контроллер управления отоплением NEUROBAT [6]. Алгоритм контроллера был разработан и протестирован как совместный проект между CSEM (Centre Suisse d'Electronique et de Microtechnique – ведущая организация), инженеринговой компанией ESTIA Ltd, промышленным партнером SAUTER и LESO-PB (Solar Energy and Building Physics Laboratory, Швейцария).



■ Рис. 2. Искусственная нейронная сеть (ИНС): входной слой, скрытый слой, выходной слой

В настоящее время простейшее управление системами отопления основано на кривых отопления, которые определяют зависимость между температурой теплоносителя в зависимости от температуры наружного воздуха. Это управление без обратной связи. Данная концепция не позволяет существенно оптимизировать энергопотребление, достичь высоких показателей теплового комфорта и требует значительных усилий при вводе в эксплуатацию. Более совершенные алгоритмы предусматривают непрерывный учет теплоты от солнечной радиации или внутренних бытовых тепловыделений, однако и они не позволяют решать задачи оптимального управления теплопотреблением здания.

Швейцарскими специалистами был разработан алгоритм управления отоплением на основе нейросетей и создан контроллер, реализующий этот алгоритм. Контроллер реализует предиктивную (прогнозирующую) оптимальную стратегию управления на основе математической модели теплофизических характеристик здания, поведения пользователя и прогноза погоды за счет использования самообучающихся алгоритмов нейросетей. Алгоритм оптимального управления направлен на оптимизацию теплового комфорта при минимизации энергопотребления.

В качестве входных сигналов используются данные от стандартных датчиков: температуры

наружного воздуха, интенсивности солнечной радиации (посредством двух измерений температуры воздуха: один датчик температуры подвергается воздействию прямого солнечного излучения, а другой – защищен от солнца; разность температуры пропорциональна солнечному излучению), температуры подаваемого и обратного теплоносителя, температуры воздуха в помещении. Влияние пользователя ограничивается заданием температуры в помещении и графика использования помещения. Функции самообучения алгоритма управления не требуют дополнительного определения параметров или адаптации параметров при вводе в эксплуатацию. Контроллер адаптирует и оптимизирует параметры моделей здания и наружного климата посредством самообучения во время работы.

Имитационное моделирование, а затем и испытания на реальном объекте подтвердили снижение энергопотребления на 10–15% даже по сравнению с достаточно совершенными системами управления, одновременно оптимизируя тепловой комфорт пользователя. Кроме того, применение нейросетевых алгоритмов существенно облегчает ввод оборудования в эксплуатацию и его наладку.

*В одном из следующих номеров эта система будет рассмотрена более подробно.*

## Литература

1. Табунщиков Ю. А. Математическое моделирование – универсальный инструмент управления теплоэнергоснабжением здания // АВОК. – 2018. – № 6.
2. Миллер Ю. В., Бродач М. М., Шилкин Н. В. Оценка потенциала энергосбережения при применении автоматизированной системы управления теплоэнергоснабжением и микроклиматом здания // АВОК. – 2018. – № 6.
3. Табунщиков Ю. А., Бродач М. М. Математическое моделирование и оптимизация тепловой эффективности зданий. М.: АВОК-ПРЕСС, 2002.
4. Табунщиков Ю. А. Здание должно мыслить // АВОК. – 2016. – № 1.
5. Табунщиков Ю. А., Бродач М. М. Искусственный интеллект в управлении теплоэнергоснабжением здания // АВОК. – 2018. – № 8.
6. Krauss J., Bauer M., Bichsel J., Morel N. Energy and HVAC: NEUROBAT – a Self-Commissioned Heating Control System Using Neural Networks / In book: Sensors in Intelligent Buildings. Vol. 2. P. 63–83. □