



Прогнозирование тепловой нагрузки на отопление с использованием ИНС

Рецензия эксперта на статью получена 30.10.2019 [Expert review on the article received on October 30, 2019].

Статья подготовлена по результатам проекта, выполненного при поддержке Российского научного фонда (уникальный идентификатор гранта РНФ №16-19-20568).

Среди большого количества научных работ, посвящённых применению нейросетевого моделирования в энергетике, лидирующую позицию занимает прогнозирование электропотребления. Взаимоотношения поставщика и промышленного потребителя на оптовом рынке электроэнергии и мощности заставляют последнего предоставлять данные о плановом почасовом графике электропотребления. Отклонения фактического графика от планового приводят к убыткам для промышленных потребителей.

Не менее актуальной является задача прогнозирования теплоснабжения. Преимущество в прогнозном графике теплоснабжения — отсутствие «перетопа» или «недотопа» у потребителя, рациональное использование топлива на источнике тепловой энергии, оптимальные тепловые потери в тепловых сетях, корректный подбор характеристик оборудования тепловых пунктов и инженерных коммуникаций здания. Перечисленные преимущества повышают уровень энергосбережения и, как следствие, приводят к экономии денежных средств.

Существующие методы расчёта тепловых нагрузок здания, которые основаны на нормативных документах РФ, всё чаще показывают несовместимость с принципами энергосбережения. Большинство

параметров и коэффициентов, используемых в расчёте, являются укрупнёнными и статичными. При расчёте тепловой нагрузки на отопление результатом является максимальная нагрузка с необоснованным запасом. Из-за большого количества влияющих параметров, которые имеют различный вклад в физику процесса тепломассообмена, очень проблематично описать одним или несколькими уравнениями динамическую модель теплового потребления здания. Ввиду этого предлагается оценить возможность применения нейросетевого прогнозирования при расчёте тепловой нагрузки на систему отопления.

Отсутствие «перетопа» или «недотопа» у потребителя, рациональное использование топлива на источнике тепловой энергии, оптимальные тепловые потери в тепловых сетях, корректный подбор характеристик оборудования тепловых пунктов и инженерных коммуникаций здания. Перечисленные преимущества повышают уровень энергосбережения и, как следствие, приводят к экономии денежных средств

УДК 697.1. Научная специальность: 05.14.04.

Прогнозирование тепловой нагрузки на отопление с использованием ИНС

А. О. Барабанов, аспирант; **С. В. Гузов**, к.т.н., доцент, кафедра тепломассообменных процессов и установок (ТМПУ), Национальный исследовательский университет «Московский энергетический институт» (НИУ «МЭИ»)

Цель работы — рассмотреть возможность применения искусственных нейронных сетей (ИНС) для прогнозирования тепловой нагрузки на отопление. В программном комплексе Statistica были обучены, протестированы и проверены на контрольных значениях несколько автоматизированных нейронных сетей, различающихся по структуре. Массив входных и выходных (обучающих) данных был составлен на основе уравнения теплового баланса. При различных известных значениях основных составляющих теплового баланса была рассчитана тепловая нагрузка на отопление. На контрольных данных при подборе пяти моделей минимальное среднее относительное отклонение составило 4,64 %.

Ключевые слова: искусственная нейронная сеть, многослойный перцептрон, тепловая нагрузка на отопление, тепловой баланс.

UDC 697.1. The number of scientific specialty: 05.14.04.

Prediction of thermal load on the heating system using artificial neural networks

A. O. Barabanov, postgraduate student; **S. V. Guzhov**, PhD, Associate Professor, the Department of Heat and Mass Transfer Processes and Plants, National Research University "Moscow Power Engineering Institute" (NRU "MPEI")

The purpose of the work is to consider the possibility of using artificial neural networks to predict the heat load of heating. In the Statistica software package, several automated neural networks, differing in structure, were trained, tested and tested on control values. An array of input and output (training) data was compiled based on the heat balance equation. For various known values of the main components of the heat balance, the heat load for heating was calculated. On the control data, when selecting five models, the minimum average relative deviation was 4.64 %.

Keywords: artificial neural network, multilayer perceptron, thermal load on the heating system, heat balance.

Для достижения цели работы решаются следующие задачи:

1. Дать краткую характеристику нейронным сетям.
2. С помощью программного комплекса Statistica подобрать наилучшую нейронную модель.
3. После обучения на эталонных (обучающих) данных получить минимальное отклонение на контрольных значениях.

ИНС — искусственная нейронная сеть, то есть набор элементарных преобразователей информации — нейронов, соединённых друг с другом каналами обмена информацией для их совместной работы. В настоящее время сформировались две ветви исследований. Первая, нейробиологическая, основывается на моделировании работы живого мозга, имея целью объяснить, каким образом в нём отображаются сложные объекты и связи между ними, как устанавливаются соответствие между хранящейся и поступающей извне информацией, как мозг обучается, и другие вопросы, касающиеся функционирования мозга. Второе направление исследований направлено на решение с помощью ИНС задач переработки информации в различных областях знаний, особенно в плохо формализуемых, где существующие модели субъективны и неадекватны. Наиболее впечатляющие результаты использования ИНС достигнуты при распознавании образов, при создании самообучающихся экспертных систем, при построении ассоциативной памяти и при решении оптимизационных задач большой размерности.

Нейрон представляет собой единицу обработки информации в нейронной сети. На блок-схеме рис. 1 показана модель нейрона, лежащего в основе искусственных нейронных сетей. В этой модели можно выделить три основных элемента.

В настоящее время сформировались две ветви исследований искусственных нейронных сетей. Первая, нейробиологическая, основывается на моделировании работы живого мозга, имея целью объяснить процессы восприятия, упорядочивания, обработки и хранения информации в нём. Вторая направлена на решение с помощью искусственных нейронных сетей задач переработки информации в различных областях знаний, особенно в плохо формализуемых, где существующие модели субъективны и неадекватны

нейрона. Эту операцию можно описать как линейную комбинацию.

3. Функция активации ограничивает амплитуду выходного сигнала нейрона. Эта функция также называется функцией сжатия. Обычно нормализованный диапазон амплитуд выхода нейрона лежит в интервале $[0, 1]$ или $[-1, 1]$.

В модель нейрона, показанной на рис. 1, включён пороговый элемент, который обозначен символом b . Эта величина отражает увеличение или уменьшение входного сигнала, подаваемого на функцию активации [1].

Многослойные перцептроны (рис. 2) также называют «простыми нейронными сетями прямого распространения».




Рис. 1. Модель нейрона

1. Набор синапсов или связей, каждый из которых характеризуется своим весом или силой. В отличие от синапсов мозга, синаптический вес искусственного нейрона может иметь как положительные, так и отрицательные значения.
2. Сумматор складывает входные сигналы, взвешенные относительно синапсов

Их можно рассматривать как обобщение линейных моделей, которые, прежде чем прийти к решению, выполняют несколько этапов обработки данных.

Самым важным свойством нейронных сетей является их способность обучаться на основе данных окружающей среды и в результате обучения повышать свою производительность. Обучение нейронной сети происходит посредством итеративного процесса корректировки синаптических весов и порогов. Обучение — это процесс, в котором свободные параметры нейронной сети настраиваются посредством моделирования среды, в которую эта сеть встроена. Тип обучения определяется способом подстройки этих параметров. Это определение процесса обучения предполагает следующую последовательность событий:

1. В нейронную сеть поступают стимулы из внешней среды.
2. В результате этого изменяются свободные параметры нейронной сети.
3. После изменения внутренней структуры нейронная сеть отвечает на возбуждение уже иным образом [2].




Рис. 2. Иллюстрация многослойного перцептрона с одним скрытым слоем

Задачей данной работы является обучить нейронную сеть прогнозировать тепловую нагрузку на отопление. Входными переменными будут являться компоненты теплового баланса здания [3]:


$$Q_{COmax} = Q_{тп} - Q_{быт}. \quad (1)$$

Тепловая нагрузка системы отопления зависит от коэффициента теплопередачи, площади поверхности ограждающих конструкций, температуры воздуха внутри помещения, температуры наружного воздуха, массового расхода инфильтрующегося воздуха, площади комнаты, массового расхода воздуха на вентиляцию, количества людей, установленной мощности осветительных и бытовых приборов. Выходным (прогнозным) значением являлась тепловая нагрузка на систему отопления. Обучающая выборка составляла 264 набора входных и выходных переменных.

В программном комплексе Statistica [4] было подобрано пять автоматизированных моделей нейронных сетей:

1. MLP 10-11-1. Многослойный персептрон с 11 нейронами в скрытом слое. Активационная функция нейронов скрытого и выходного слоёв — экспоненциальная. Среднее относительное отклонение выходных данных сети на тренировочных данных — 6,33 %, на тестовых данных — 8,32 %, на контрольных данных — 10,88 %.

2. MLP 10-9-1. Многослойный персептрон с девятью нейронами в скрытом слое. Активационная функция скрытого слоя — логистическая, выходного слоя — тождественная. Среднее относительное отклонение выходных данных сети на тренировочных данных — 5,28 %, на тестовых данных — 19,5 %, на контрольных данных — 6,8 %.



3. MLP 10-8-1. Многослойный персептрон с восемью нейронами в скрытом слое. Активационная функция нейронов скрытого слоя — логистическая, выходного слоя — тангенциальная. Среднее относительное отклонение выходных данных сети на тренировочных данных — 4,73 %, на тестовых данных — 33,68 %, на контрольных данных — 9,34 %;

4. MLP 10-12-1. Многослойный персептрон с 12 нейронами в скрытом слое. Активационная функция нейронов скрытого слоя — логистическая, выходного

слоя — тангенциальная. Среднее относительное отклонение выходных данных сети на тренировочных данных — 2,41 %, на тестовых данных — 3,8 %, на контрольных данных — 4,64 %.

5. MLP 10-13-1. Многослойный персептрон с 13 нейронами в скрытом слое. Активационная функция нейронов скрытого слоя — экспоненциальная, выходного слоя — тождественная. Среднее относительное отклонение выходных данных сети на тренировочных данных — 6,18 %, на тестовых данных — 8,31 %, на контрольных данных — 8,12 %.

Таким образом, на основе подобранных моделей можно сделать вывод о том, что наилучшим вариантом является модель сети MLP 10-12-1 с наименьшим средним относительным отклонением 4,74 %. Применяемый программный комплекс Statistica позволяет без углублённых знаний программирования и нейронных сетей подобрать различные структуры, обучить модель на тренировочных данных и получить прогноз на контрольных.

Нейронные сети способны к обучению и прогнозированию достаточно близких к истинным зависимостям, а не простому «угадыванию». При правильном выборе набора входных переменных, а также структуры сети возможно получить более точное прогнозирование. ●

При правильном выборе набора входных переменных, а также структуры нейронной сети возможно получить более точное прогнозирование



1. Хайкин С. Нейронные сети: полный курс. Изд. 2-е / Пер. с англ. и ред. Н.Н. Куссуль. — М.: Вильямс, 2016. 1104 с.
2. Элементарное введение в технологию нейронных сетей с примерами программ / Р. Тадеусевич, Б. Боровик, Т. Гончаж, Б. Леппер; пер. с польск. И.Д. Рудинского. — М.: Горячая Линия — Телеком, 2011. 408 р.
3. Малявина Е.Г. Тепловые потери здания: справ. пособ. — М.: АВОК-Пресс, 2007. 144 с.
4. Statistica: Автоматизированные нейронные сети [Электр. ресурс]. StatSoft Russia. Режим доступа: statsoft.ru. Дата обрац.: 01.07.2019.

References — see page 94.

Prediction of thermal load on the heating system using artificial neural networks. Pp. 58–60.

Alexander O. Barabanov, postgraduate student; **Sergey V. Guzhov**, PhD, Associate Professor, the Department of Department of Heat and Mass Transfer Processes and Plants, National Research University "Moscow Power Engineering Institute"

1. Hajkin S. *Nejronnye seti: polnyj kurs* [Neural networks: A full class]. 2nd edition. Transl. from English and edited by N.N. Kussul'. Moscow. *Vil'jams* ["Williams" Publishing House]. 2008. 1104 p. [In Russian]
2. Tadeusevich R., Borovik B., Gonchazh T., Leper B. *Jelementarnoe vvedenie v tehnologiju nejronnyh setej s primerami program* [An elementary introduction to the technology of neural networks with examples of programs]. Transl. from Polish by I.D. Rudinsky. Moscow. *Gorjachaja Linija — Telekom* ["Hot Line — Telecom" Publishing House]. 2011. 408 p. [In Russian]
3. Maljavina E.G. *Teplopoteri zdanija: sprav. posob.* [Heat loss of the building: A reference guide]. Moscow. *AVOK-Press* [Publishing House of the Russian Association of Engineers for Heating, Ventilation, Air-Conditioning, Heat Supply and Building Thermal Physics ("ABOK-Press")]. 2007. 144 p. [In Russian]
4. Statistica Automated Neural Networks. StatSoft Russia. Web-source: statsoft.ru. Access data: July 1, 2019. [In Russian]