

Прогнозирование тепловой нагрузки на отопление с использованием ИНС**Prediction of heat load on heating using artificial neural networks**

Барabanов Александр Олегович, аспирант кафедры ТМПУ, НИУ МЭИ, г. Москва, 89257835359, barabanoff1995@mail.ru

Barabanov Alexander Olegovich, Postgraduate Student, Department of TMPU, NRU MPEI, Moscow, 89257835359, barabanoff1995@mail.ru

Гужов Сергей Вадимович, к.т.н., доцент кафедры ТМПУ, НИУ МЭИ, г. Москва, 89652949111, guzhovsv@yandex.ru

Guzhov Sergey Vadimovich, Candidate of Technical Sciences, Associate Professor of the Department of TMPU, NRU MPEI, Moscow, 89652949111, guzhovsv@yandex.ru

Аннотация: Цель работы – рассмотреть возможность применения искусственных нейронных сетей 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%.

Annotation: 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%.

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

Key words: artificial neural network, multilayer perceptron, thermal load on heating, heat balance.

Среди большого количества научных работ, посвященных 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 теплопотребления. Преимущества в прогнозном графике теплопотребления – 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 расчета тепловых нагрузок здания, которые основаны на нормативных документах РФ, все чаще показывают несовместимость с принципами энергосбережения. Большинство параметров и коэффициентов, используемых в расчете, являются укрупненными и статичными. При расчете тепловой нагрузки на отопление результатом является максимальная нагрузка с необоснованным запасом. Из-за большого количества влияющих параметров, которые имеют различный вклад в физику процесса теплообмена, очень проблематично описать одним или несколькими уравнениями динамическую модель теплового потребления здания. В виду этого предлагается оценить возможность применения нейросетевого прогнозирования при расчете тепловой нагрузки на систему отопления. Для достижения цели работы, решаются следующие задачи:

- 1) Дать краткую характеристику нейронным сетям;
- 2) С помощью программного комплекса Statistica подобрать наилучшую нейронную модель.

После обучения на эталонных (обучающих) данных, получить минимальное отклонение на контрольных значениях.

Искусственная нейронная сеть (ИНС) – набор элементарных преобразователей информации – нейронов, соединенных 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 нем 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.




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 соответствующих синапсов 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, показанную на рис. 1, включен пороговый элемент, который обозначен символом b . Эта величина отражает увеличение или уменьшение входного сигнала, подаваемого на функцию активации [1].

Многослойные персептроны (рис. 2.) также называют простыми нейронными сетями прямого распространения и его можно рассматривать как обобщение линейных моделей, которое прежде чем прийти к решению выполняет несколько этапов обработки данных.




Рис. 2. Иллюстрация многослойного персептрона с одним скрытым слоем

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 интерактивного 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 возбуждения уже иным образом [2].

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

$$Q_{CO}^{\max} = Q_{TH} - Q_{быт} \quad (1)$$

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 (прогноznым) 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 9 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 8 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 углубленных 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.

Список литературы

1) Хайкин Саймон. Нейронные сети: полный курс (пер. с англ. Н. Н. КуССуль, А. Ю. Шелестова) // Изд. 2-е, испр. - Москва [и др.]: Вильямс, 2008. - 1103 с.

2) Тадеусевич Р., Боровик Б., Гончаз Т., Леппер Б. Элементарное введение в технологию нейронных сетей с примерами программ. Перевод с польск. И.Д. Рудинского // М.: Горячая линия - Телеком, 2011. — 408 с.

3) Е.Г. Малявина. Теплотери здания. Справочное пособие // АВОК-ПРЕСС, 2007. - 144 с.

4) STATISTICA Автоматизированные нейронные сети [Электронный ресурс] / StatSoft Russia. Режим доступа: http://statsoft.ru/products/STATISTICA_Neural_Networks/. Дата обращения: 01.07.2019.

1) Hajkin Sajmon. Nejrornyie seti: polnyj kurs (per. s angl. N. N. Kussul', A. YU. Shelestova) [Neural networks: full course (translated from English by N.N. Kussul, A. Yu. Shelestov)] // Publishing House. 2nd, rev. - Moscow [et al.]: Williams, 2008. - 1103 p.

2) Tadeusevich R., Borovik B., Gonchazh T., Lepper B. Elementarnoe vvedenie v tekhnologiyu nejronnyh setej s primerami programm. Perevod s pol'sk. I.D. Rudinskogo [An elementary introduction to the technology of neural networks with examples of programs. Translation from polish. I.D. Rudinsky] // M.: Hot line - Telecom, 2011. -- 408 p.

3) E.G. Malyavina. Teplopoteri zdaniya. Spravochnoe posobie [Heat loss of the building. Reference manual] // AVOK-PRESS, 2007. - 144 p.

4) STATISTICA Avtomatizirovannye nejronnyie seti [STATISTICA Automated Neural Networks]. StatSoft Russia. Web-source: http://statsoft.ru/products/STATISTICA_Neural_Networks/. Access data: July 1, 2019. [In Russian].