

УДК 629.1:629.7

С.В. Артеменко

Одесская национальная академия пищевых технологий, учебно-научный институт холода, криотехнологий и экоэнергетики им. В.С. Мартыновского, ул. Дворянская, 1/3, Одесса, 65082

НЕЙРОСЕТЕВОЕ ПРОГНОЗИРОВАНИЕ СВОЙСТВ ХЛАДАГЕНТОВ: ОБЗОР

В работе проведен обзор статей, связанных с моделированием свойств хладагентов с помощью искусственных нейронных сетей, представляющих альтернативу прогнозированию термодинамических свойств веществ на основе аппарата термодинамики. В статье обсуждается эффективность, адекватность и ограничения применения этого подхода.

Ключевые слова: Искусственные нейронные сети – Свойства хладагентов – Фазовое равновесие

С.В. Артеменко

Одеська національна академія харчових технологій, навчально-науковий інститут холоду, кріотехнологій та екоенергетики ім. В.С. Мартиновського, вул. Дворянська, 1/3, Одеса, 65082

НЕЙРОМЕРЕЖЕВЕ ПРОГНОЗУВАННЯ ВЛАСТИВОСТЕЙ ХОЛОДОАГЕНТІВ: ОГЛЯД

В роботі проведено огляд статей, пов'язаних з моделюванням властивостей холодоагентів за допомогою штучних нейронних мереж, що представляють альтернативу прогнозуванню термодинамічних властивостей речовин на основі апарату термодинаміки. У статті обговорюється ефективність, адекватність і обмеження застосування цього підходу.

Ключові слова: Штучні нейронні мережі – Властивості холодоагентів – Фазова рівновага

DOI: 10.15673/0453-8307.6/2014.30992



This work is licensed under the Creative Commons Attribution International License (CC BY).
<http://creativecommons.org/licenses/by/4.0/>

I. ВВЕДЕНИЕ

Моделирование свойств хладагентов занимает значительную часть сегмента исследований, проводимых в области холодильной техники. Основные задачи моделирования свойств связаны с повышением эффективности процессов теплопереноса, а также созданием новых веществ, отвечающих требованиям экологической безопасности. Теплофизические свойства определяются как с помощью экспериментальных исследований, так и описываются с помощью классических подходов термодинамики, молекулярной физики, методов физической химии и квантово-механических расчетов *ab initio*.

Подходы, которые были развиты для получения сведений о термодинамических свойствах веществ, когда круг соединений был небольшим, использовали парадигму ограниченности данных, которая базировалась на длительных экспериментах и имитационном моделировании. Экспоненциальный рост работ в области неэмпирических квантовомеханических расчетов молекулярных структур и молекулярно-динамических компьютерных экспериментов, наряду с данными измерений различных физико-химических величин в ре-

зультате мониторинга технологических процессов, привел к перенасыщению данными.

Наиболее перспективное направление заключается в использовании информационных технологий и создании киберинфраструктуры, которая способна осуществлять переработку больших потоков данных и извлекать возможные закономерности при помощи методов искусственного интеллекта. К таким методам относятся экспертные системы, нейронные сети, генетические алгоритмы, теория нечеткой логики и гибридные алгоритмы.

Для задач прогноза и моделирования свойств веществ по заданным параметрам наилучшим образом адаптированы искусственные нейронные сети (ИНС). Основными преимуществами ИНС являются их скорость, простота и возможность определения комплексных нелинейных взаимосвязей между переменными путем обучения системы и дальнейшего применения для прогнозирования [1]. Нейронные сети справляются с решением задачи выявления связей между входными и выходными параметрами модели без сложных теоретических уравнений, а лишь на основе тренировочного набора данных.

Искусственные нейронные сети представляют собой математический аппарат, который в про-

цессе обучения позволяет установить зависимости между входными данными и выходными характеристиками любой степени сложности. Цель обучения – найти коэффициенты связей между нейронами, которые определяют способности нейронной сети к выделению скрытых зависимостей между входными и выходными величинами. После обучения сеть, становится способной к прогнозированию новых данных на основе ограниченной выборки известных взаимосвязей между входными и выходными величинами.

Обзоры применения нейронных сетей затрагивают различные аспекты процессов сушки [2], прогнозирования атмосферных явлений [3], прикладных задач солнечной энергетики [4] и моделирования традиционных энергетических систем [5-8]. В настоящей работе рассматриваются результаты описания теплофизических свойств веществ методами ИНС.

II. ОБЗОР АРХИТЕКТУРЫ НЕЙРОННЫХ СЕТЕЙ

Простейшая структура нейроподобного элемента, которая используется при моделировании нейронных сетей, приведена на рисунке 1. На нейроподобный элемент поступает набор входных сигналов x_1, x_2, \dots, x_m , который определяет вектор X , представляющий, в свою очередь, набор других нейроподобных элементов. Каждый входной сигнал умножается на соответствующий вес связи w_1, w_2, \dots, w_n .




Рисунок 1 – Структура нейроподобного элемента

Вес связи является скалярной величиной, положительной для возбуждающих и отрицательной для тормозящих связей. Входные сигналы со своими весами поступают на блок суммации, где определяется степень возбуждения нейроподобного элемента S :

$$S = \sum_{i=1}^M w_i x_i, \quad (1)$$

Выходной сигнал нейрона y определяется путем пропускания уровня возбуждения S через нелинейную функцию f

$$y = f(S - \theta), \quad (2)$$

где θ - некоторое постоянное смещение. Обычно используются простейшие функции: бинарная (рисунки 2, а)

$$y = \begin{cases} 1 & \text{при } S > \theta, \\ 0 & \text{при } S \leq \theta \end{cases} \quad (2a)$$

сигмоидальная (рисунок 2, б)

$$y = 1 / (1 + e^{-(S-\theta)}) \quad (26)$$

Нейронная сеть представляет собой совокупность нейроподобных элементов, определенным образом соединенных друг с другом и с внешней средой. В процессе функционирования сети осуществляется преобразование входного вектора в выходной. Конкретный вид выполняемых преобразований информации обусловлен не только характеристиками нейронной сети, но и особенностями ее архитектуры, т.е. той или иной топологией межнейронных связей, выбором определенных подмножеств элементов для ввода и вывода информации, направлением, способами управления потоками между нейронами [9].




Рисунок 2 – Различные типы передаточных функций.

Одним из важнейших свойств сети является способность к обучению, с целью улучшения ее функционирования. Нейронные сети настраиваются и обучаются таким образом, чтобы заданные входные сигналы вели к определенному требуемому результату. Существует целый ряд алгоритмов для обучения нейронных сетей, главным образом, использующих идею увеличения силы взаимодействия (веса) между одновременно активными нейронами при обучении [9]. Математическое это правило выражается следующим образом:

$$\omega_{ij}(t+1) = \omega_{ij}(t) + \alpha y_i y_j, \quad (3)$$

где $\omega_{ij}(t)$ и $\omega_{ij}(t+1)$ – значение веса связи от i -го к j -му нейрону соответственно до и после его изменения, α - скорость обучения.

Простейшей моделью нейронной сети является модель персептрона [10], состоящая из бинарных нейроподобных элементов и имеющая простую топологию (рис.3). Модель персептрона характеризуется наличием только прямых связей,

один из слоев которых является модифицируемым. В простейшем случае, когда $x_i = p_i$ и $n = m$, персептрон становится одним бинарным нейроподобным элементом. Это классическая модель М - входного нейрона или простой персептрон Розенблатта. В общем случае каждый элемент x_i может рассматриваться как булевская функция, зависящая от некоторого фиксированного уровня входных сигналов. Тогда величина выходных сигналов для этих обрабатывающих элементов является значением функции x_i , которое равно 0 или 1. Для обучения такой сети применим т.н. метод сходимости персептрона Розенблатта [10], который является вариантом Хеббовского правила изменения весов связей с наблюдателем.

К расширению понятия персептрона можно отнести линейные нейронные сети, в которых в качестве передаточной функции используется линейная функция (рисунок 2, в), вместо бинарной передаточной функции для простого персептрона. Это позволяет выходам сети принимать любые

значения, несмотря на то, что выход персептрона ограничен 0 или 1. Архитектура линейной сети представлена на рис. 3б. Линейные сети могут решать только линейно-сепарабельные задачи. Разница между вектором выхода и целевым вектором является ошибкой сети. Нахождение весов и смещений осуществляется таким образом, чтобы функция эффективности, в большинстве случаев среднеквадратическая ошибка, была наименьшей. Задача допускает применение хорошо разработанных алгоритмов, для которых достигается единственный минимум среднеквадратичной ошибки. Для обучения сети в большинстве случаев предпочтение отдают методу Уидроу - Хоффа [11].

Аналогичная идея обучения используется применительно к многослойным персептронам и нелинейным дифференцируемым передаточным функциям в методе *обратного распространения ошибки (back propagation)* [12]. Сеть такого типа представлена на рисунке 3в.

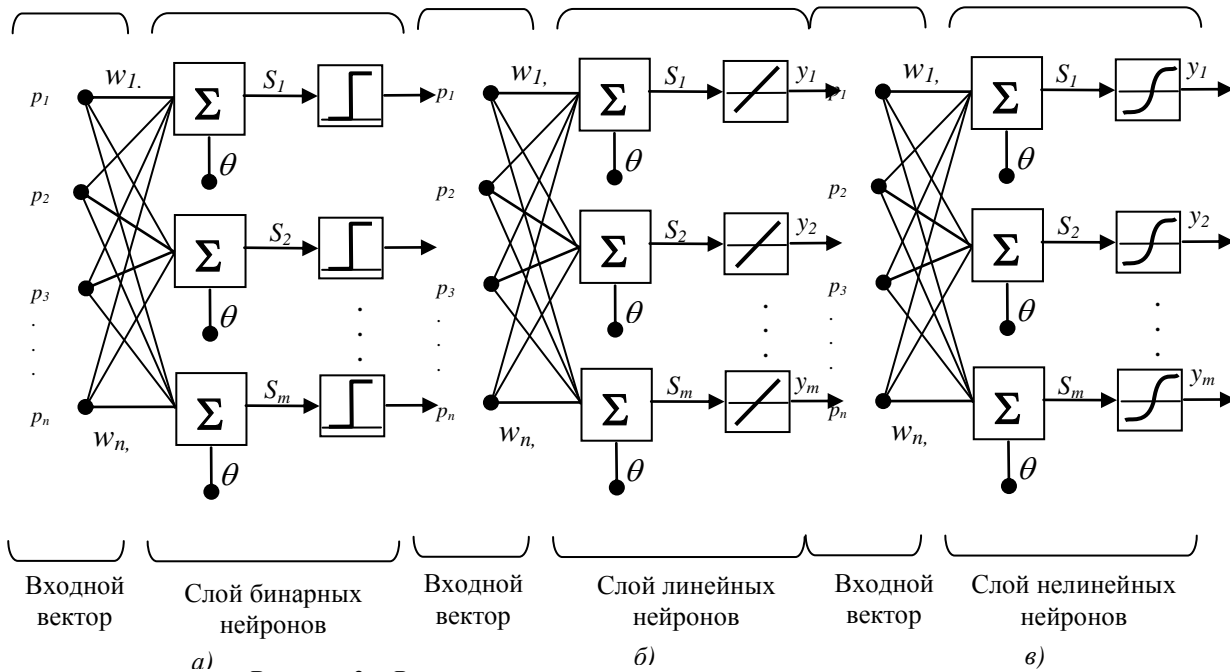


Рисунок 3 – Различные типы построения нейронных сетей

Надо отметить, что выходной слой практически всегда является линейным. Сам по себе термин «обратное распространение» относится к методу, с помощью которого вычисляется градиент для нелинейной многослойной сети. Алгоритм обратного распространения ошибки суть обобщение процедуры метода Уидроу – Хоффа. Выборка, участвующая в обучении, состоит из набора пар массивов, между которыми должно быть установлено соответствие.

Рассмотрим многослойную нейронную сеть с прямыми связями. Входные элементы образуют первый (нижний) слой сети, выходные – последний (верхний). Между ними находятся слои скрытых нейронных блоков. Каждый блок соединяется

модифицируемой связью (весом) с любым другим блоком соседних слоев, но блоки одного слоя не могут содержать связей.

Каждый блок посылает выходной сигнал только в вышележащие слои и принимает входные сигналы только от предыдущих слоев. Входной вектор подается на нижний слой, а выходной вектор определяется путем последовательного вычисления уровней активности элементов каждого слоя «снизу – вверх» с использованием известных значений активности элементов предшествующих слоев. Скрытые слои используются для представления области знаний.

Шагом, предшествующим обучению, является инициализация сети – присваивание небольших

случайных значений. Каждая итерация состоит из двух фаз. В течение первой фазы на сеть подается входной вектор с помощью установки в требуемое состояние входных элементов. Затем входные сигналы распространяются по сети, вызывая некоторый выходной вектор. Условием работы алгоритма является неубываемость характеристики вход – выход и наличие ограниченной производной. Этим требованиям отвечают передаточные функции сигмоидального вида (рисунок 2 б, г). Сгенерированный выходной вектор сравнивается с требуемым (целевым вектором). При наличии ошибки (разности между целевыми и выходными значениями) вычисляется разница между фактическими и требуемыми выходными значениями, которая передается последовательно обратно по направлению выход – вход. Основные этапы функционирования алгоритма тренировки сети представлены на рисунке 5.




Рисунок 4 – Схема многослойной нейронной сети



Рисунок 5 – Схема обучения нейронной сети

Основываясь на информации об ошибке, связи (веса) модифицируются согласно с обобщенным правилом Уидроу – Хоффа [11]:

$$\Delta_p \omega_{ij} = \eta \delta_{ip} y_{jp}, \quad (4)$$

где изменение в силе связи ω_{ij} для p -ой обучающей пары пропорционально произведению сигнала ошибки j -го блока, получающего входной сигнал по этой связи, и выходного сигнала блока i , посылающего сигнал по этой связи. Определение сигнала ошибки является рекурсивным процессом,

который начинается с выходных блоков. Для выходного блока сигнал ошибки:

$$\delta_{jp} = y_j (d_{jp} - o_{jp}), \quad (5)$$

где d_j и o_j – желаемое и действительное значение выходного j -го блока; y_j – характеристика нелинейности блока. Сигнал ошибки для скрытого блока определяется рекурсивно через сигнал ошибки блоков, с которыми соединен его вход, а веса этих связей:

$$\delta_{jp} = y_j \sum_k \delta_{kp} \omega_{kj}. \quad (6)$$

Модификация весов производится после предъявления каждой пары вход-выход. Однако если коэффициент η , определяющий скорость обучения, мал, то можно показать, что обобщенное правило Уидроу – Хоффа хорошо аппроксимирует минимизацию общей ошибки функционирования сети D методом градиентного спуска в пространстве весов. Общая ошибка функционирования сети определяется следующим образом:

$$D = 1/2 \sum_p \sum_j (o_{jp} - d_{jp})^2. \text{ Обучение продолжается}$$

до тех пор, пока ошибка не уменьшится до заданной величины. Эмпирически обнаружено, что при малых η система находит достаточно хороший минимум D .

Одним из недостатков алгоритма обратного распространения ошибки является тот факт, что во многих случаях для сходимости может потребоваться многократное предъявление всей обучающей выборки. Задачу повышения скорости обучения решают, например, использованием информации о второй производной D , или увеличением η . В последнем случае избежать осцилляций позволяет инерционный член:

$$\Delta \omega_{ij}(t+1) = \eta \delta_j y_i + \alpha \Delta \omega_{ij}(t), \quad (7)$$

где α – экспоненциально затухающий множитель, определяющий относительное воздействие текущего и предшествующих градиентов на изменение веса.

Сети со сигмоидальными слоями, смещениями и линейным выходным слоем могут аппроксимировать любую функцию с конечным числом разрывов. Как было указано выше, стандартным алгоритмом, реализующимся в классическом методе обратного распространения ошибки, является метод градиентного спуска [13], в котором, как и в методе Уидроу – Хоффа, сетевые веса смещаются вдоль отрицательного градиента функции эффективности обучения. Существует целый ряд модификаций основного алгоритма обучения, включая метод сопряженных градиентов, метод Ньютона или Левенберга – Марквардта, которые отражают современные достижения в алгоритмах решения нелинейных систем уравнений [14-17]. Выбор метода обучения не является универсальным и каждая новая задача требует собственного подхода к ее решению.

Кроме рассмотренных выше типов нейронных сетей в литературе представлен ряд других сетей: радиальные сети точной аппроксимации [18], рекуррентные сети Хопфильда и Елма [19], карты Кохонена [20] и др.

III. ИСПОЛЬЗОВАНИЕ НЕЙРОННЫХ СЕТЕЙ ДЛЯ РАСЧЕТА ТЕРМОДИНАМИЧЕСКИХ И ТРАНСПОРТНЫХ СВОЙСТВ ВЕЩЕСТВ

Аппарат искусственных нейронных сетей успешно применялся в работах [21–23] для предсказания таких термодинамических и теплофизических свойств веществ как удельный объем, энтальпия и энтропия в области насыщенного пара и жидкости, а также перегретого состояния пара для смесей хладагентов R404A, R407C и R508A. Авторы представили нейронные сети в результате работы которых, были получены результаты в интервале экспериментальной погрешности. Коэффициенты детерминации для описания экспериментальных данных составили 0,9999, как для области насыщенного пара, так и перегретого пара. Результаты этой работы полностью подтверждают адекватность использования искусственных нейронных сетей для предсказаний как азеотропных, так и зеотропных и около – азеотропных смесей.

Нейросетевая модель вязкости хладагента R152a была описана Скалабриным и Кристофали [24]. Разработанная ими многослойная нейронная сеть содержит два входных параметра: температура и плотность и один выходной параметр, представляющий собой вязкость. Работа сети, содержащая восемь нейронов в скрытом слое предсказывает значения вязкости хладагента в заданном диапазоне с отклонениями от экспериментальных значений в пределах 0,36 - 0,49%. В схожей работе Мохебби и др. [25] предсказали плотность в области насыщенной жидкости для 19 чистых и 6 смесей хладагентов. В их работе, оптимальное количество нейронов в скрытом слое было найдено с помощью генетического алгоритма. Авторы разработали многослойную нейронную сеть с ацентрическим фактором и приведенной температурой в качестве входных параметров модели и приведенной плотностью жидкости в качестве выходного параметра. Полученные результаты соответствуют как экспериментальным данным, так и корреляциям Ханкинсона и Томсона, Риделя и модификации Спенсера и Даннера метода Ракетта со средней погрешностью 1,46% для чистых веществ и 3,53% для смесей. Использование генетического алгоритма позволяет оптимизировать структуру сетей и проводить более качественное обучение.

Сенкан и др. [26] использовали нейронные сети для определения теплофизических свойств смесей 5 таких хладагентов как R413A, R417A, R422A, R422D и R423A. Представленная сеть содержит три входных параметра, представляющими температуру, давление жидкости и пара. Семь вы-

ходных параметров представлены теплопроводностью жидкости и пара, динамическим и кинематическим коэффициентом вязкости, коэффициентом термодиффузии, а также плотностью и приведенной теплоемкостью. Топология сети определяется одиннадцатью нейронами в скрытом слое.

Давление пара и значение плотности диметилаэфира (RE170) были рассчитаны с помощью нейронных сетей в работе [27]. Авторы разработали две сетевые модели - одна для предсказания давления пара и другая для предсказания плотности RE170. Первая модель нейронной сети содержит два входных параметра: температуру и давление, два скрытых слоя с 12 и 15 нейронами и один выходной параметр – плотность. Другая модель с входным параметром – температурой и выходным параметром – давлением пара построена на основе однослойной архитектуры с двумя нейронами. Погрешность расчетов для предсказания давления пара и плотности составляет менее 0,04% и 0,16%, соответственно. Курт и Кайфеци [28] предсказали теплопроводность раствора этиленгликоль – вода (широко используемого рабочего тела в охладителях систем вентиляции), используя в качестве входных параметров модели температуру, плотность и концентрацию. Сеть с конфигурацией 3-4-1 предсказывает теплопроводность со средней ошибкой 0,7984%. Похожей является работа по предсказанию теплопроводности газов, основанных на обучении 39 хладагентов [29]. Входными параметрами для данной модели являются температура, критическая температура и критическое давление и молекулярный вес. Для обучения сети был использован набор из 236 экспериментальных данных для углеводородных и неуглеводородных компонентов. Архитектура сети была выбрана как двухслойная с 4 и 10 нейронами соответственно.

Урата и др. в работе [33] использовал нейронные сети для предсказания равновесия пар – жидкость для бинарных систем, содержащих гидрофтороэфиры. Первым шагом алгоритма предсказания является определение знака коэффициента активности для каждой из бинарных смесей при помощи аппарата нейронных сетей. Затем строятся два набора соотношений между мольной долей и коэффициентом активности и проводится расчет состава пар – жидкость и равновесной температуры, используя полученные коэффициенты активности. Входными параметрами для используемых здесь сетей является следующий набор данных: отношение точки нормального кипения к молекулярному весу, плотность и дипольный момент обоих компонентов.

В работе Артеменко и Мазура [34] аппарат нейронных сетей был применен к задаче прогнозирования азеотропного состояния в бинарных смесях хладагентов на основании набора таких входных параметров сети, как критическая температура, критическое давление и ацентрический коэффициент. Предложенный многоступенчатый алгоритм позволяет прогнозировать бинарный параметр взаимодействия k_{ij} для дальнейшего использования при расчете критерия азеотропии,

полученного с помощью техники глобальных фазовых диаграмм. Работа охватывает 1500 бинарных комбинаций хладагентов.

Мохани [35] применил нейронные сети для расчёта параметров вещества для расчета равновесия жидкость – пар для бинарной смеси диоксид углерода – дифлорметан. В качестве входных параметров системы рассматриваются температура и давление, а выходной параметр соответствует составу жидкой и паровой фазы. Архитектура сети представляется одним скрытым слоем, состоящим из 10 нейронов. Для обучения сети были использованы экспериментальные данные в диапазоне температуры 222.04 – 343.23 К и давления 0,105 и 7,46 МПа.

Нейросетевая модель прогнозирования термодинамических свойств двух альтернативных пар хладагент / абсорбент (метанол – LiBr и метанол – LiCl) была применена Созеном в работах [30, 31]. Для обучения сети использовался метод Левенберга – Марквардта, картезианского генетического программирования и метод градиентного спуска. Температура, давления и концентрация являются входными параметрами модели, а выходным параметром был предложен удельный объем смеси. Сеть использует один слой с 8 нейронами.

Сенкан и др. [32] создали сеть для предсказания энтальпии пара хлорид лития - вода и бромид лития - вода. Разработанная сеть характеризуется двумя входными параметрами – концентрацией и температурой. В качестве выходного параметра использовалось значение энтальпии пары абсорбент-хладагент.

S.V. Artemenko

Odessa National Academy of Food Technologies, Educational and Research Institute of Refrigeration, cryotechnology and Ecoenergetics n.a. V.S. Martynovskiy, 1/3 Dvoryanskaya str., Odessa, 65082

NEURAL NETWORK PREDICTION OF REFRIGERANTS PROPERTIES: REVIEW

The review of recent papers related to modeling of refrigerant properties using artificial neural networks as an alternative to conventional thermodynamic approach for modeling prediction of thermodynamic properties of refrigerants has been given in the paper. The study also discusses efficiency, adequacy and limitation of this approach.

Keywords: Artificial neural network – Properties of refrigerant – Phase equilibria

REFERENCES

1. **Zhang G.** et al. Forecasting with artificial neural networks // The state of the art. International Journal of forecasting. – 1998. – 14. – pp.35 – 62.
2. **Tayagarajan T.** et al. Artificial neural networks: Principles and application to model based control of drying systems – a review // Drying Technology. – 1998. – 16. – pp.931 – 966. DOI: 10.1080/07373939808917449
3. **Gardner M.W., Dorling S.R.** Artificial neural networks (the multilayer perceptron) – a review of applications in the atmospheric sciences // Atmospheric Environment. – 1998. – 32. – pp. 2627 – 2636. DOI: 10.1016/S1352-2310(97)00447-0
4. **Mellit A.** et al. Artificial intelligence techniques for sizing photovoltaic systems: a review // Renewable and Sustainable Energy Reviews. – 2009. – 13. – p.406 – 419. DOI: 10.1016/j.rser.2008.01.006
5. **Kalogirou S.** Applications of artificial neural networks in energy systems: a review // Energy Conversion and Management. – 1999. – 40. – pp. 1073–1087. DOI: 10.1016/S0140-6701(00)94999-3
6. **Kalogirou S.** Applications of artificial neural networks for energy systems // Applied Energy. – 2000. – 67. – pp.17–35. DOI: 10.1016/B978-0-08-043877-1.50005-X
7. **Kalogirou S.** Artificial neural networks in renewable energy systems applications: a review // Renewable and Sustainable Energy Reviews. – 2001. – 5. – pp. 373–401. DOI:10.1016/S1364-0321(01)00006-5

ВЫВОДЫ

Количество публикаций, связанных с применением нейронных сетей при моделировании и прогнозе свойств хладагентов, особенно новых рабочих веществ, заметно растет. Результаты, получаемые в результате использования нейронных сетей вполне удовлетворительны для решения задач разработки моделей описания свойств веществ. Нейросетевые модели зачастую не уступают по качеству описания эмпирическим и теоретическим моделям.

Обычно архитектура сети не превышает два слоя. В среднем число нейронов в слое не превышает 8. При нахождении оптимальной топологии сети целесообразно применение генетического алгоритма. Надо отметить, что на качество работы сети влияет процесс ее обучения, в частности отсутствие ее «перетренировки», что достигается введением т.н. валидационного набора данных.

Выполненный обзор работ в области использования нейронных сетей для описания и прогнозирования свойств хладагентов выявил следующие направления дальнейшего развития:

- I. Гибридизация нейронных сетей с другими методами искусственного интеллекта;
- II. Предсказание влияния новых хладагентов на окружающую среду;
- III. Разработка методов оптимизации сетевой конфигурации;
- IV. Фазовое поведение ранее неизученных смесей хладагентов.

8. **Михайленко В.С., Харченко Р.Ю.** Определение параметров математических моделей энергоблоков ТЭС на основе аппарата гибридных сетей // Информатика и математические методы в моделировании. – 2012. – 2(3). – с. 286-292
9. **Hebb D.O.** The Organization of Behavior. - New York: Wiley, 1949
10. **Rosenblatt F.** Principles of Neurodynamics, Washington D.C.: Spartan Press, 1961
11. **Davies M., Jones J.** // Trans. Faraday Soc. – 1954. – 50. – p. 1042
12. **Rumelhart D. E., Hinton G. E., Williams R. J.** Learning internal representations by error propagation // Parallel Data Processing.-1986.- Vol.1.- p. 318-362 DOI: 10.1016/B978-1-4832-1446-7.50035-2
13. **Moller M.F.** A scaled conjugate gradient algorithm for fast supervised learning // Neural Networks. - 1993.- Vol. 6. – p. 525-533 DOI: 10.1016/S0893-6080(05)80056-5
14. **Menhaj M.** Training feedforward networks with the Marquardt algorithm // IEEE Transactions on Neural Networks.-1994. – Vol. 5(6). – p. 989-993. DOI: 10.1109/72.329697
15. **Battiti R.** First and second order methods for learning: Between steepest descent and Newton's method // Neural Computation. – 1992. – Vol. 4(2). – p. 141-166. DOI:10.1162/neco.1992.4.2.141
16. **Riedmiller M., Braun H.** A direct adaptive method for faster backpropagation learning: The RPROP algorithm // Proceedings of the IEEE International Conference on Neural Networks. – 1993. DOI: 10.1109/ICNN.1993.298623
17. **Nguyen D., Widrow B.** Improving the learning speed of 2-layer neural networks by choosing initial values of the adaptive weights // Proceedings of the International Joint Conference on Neural Networks.- 1990.- Vol 3.- p.21-26. DOI: 10.1109/IJCNN.1990.137819
18. **Chen S., Cowan C., Grant P.** Orthogonal Least Squares Learning Algorithm for Radial Basis Function Networks // IEEE Transactions on Neural Networks. – 1991. – vol.2(2). – P. 302-309. DOI: 10.1109/72.80341
19. **Elman J.** Finding structure in time // Cognitive Science. – 1990. – vol.14. – P.179-211. DOI: 10.1207/s15516709cog1402_1
20. **Kohonen T.** Self-Organization and Associative Memory.- 2nd Edition, Berlin: Springer-Verlag, 1987
21. **Sozen A, Ozalp M, Arcaklioglu E.** Calculation for the thermodynamic properties of an alternative refrigerant (R508B) using artificial neural network // Applied Thermal Engineering. – 2007. – 27. – pp.551 – 559. DOI: 10.1016/j.applthermaleng.2006.06.003
22. **Sozen A,** et al. Determination of thermodynamic properties of an alternative refrigerant (R407C) using artificial neural network. // Expert Systems with Applications. – 2009. – 36. – pp.:4346–4356. DOI:10.1016/j.eswa.2008.05.023
23. **Sozen A, Arcaklioglu E, Menlik T.** Derivation of empirical equations for thermodynamic properties of a ozone safe refrigerant (R404A) using artificial neural network // Expert Systems with Applications. – 2010. – 37. – pp. 1158–1168. DOI: 10.1016/j.eswa.2009.06.016
24. **Scalabrin G, Cristofoli G.** The viscosity surfaces of R152a in the form of multilayer feed forward neural networks // International Journal of Refrigeration. – 2003. – 26. – pp. 302–314. DOI: 10.1016/S0140-7007(02)00113-5
25. **Mohebbi A, Taheri M, Soltani A.** A neural network for predicting saturated liquid density using genetic algorithm for pure and mixed refrigerants. International // Journal of Refrigeration. – 2008. – 31. – pp.:1317–1327. DOI: 10.1016/j.ijrefrig.2008.04.008
26. **Sencan A, Kose II, Selbas R.** Prediction of thermophysical properties of mixed refrigerants using artificial neural network // Energy Conversion and Management. - 2011. – 52. – pp.:958–974. DOI: 10.1016/j.enconman.2010.08.024
27. **Moghadassi A.R., Nikkholgh M.R., Parvizian F., Hosseini S.M.** Estimation of thermophysical properties of dimethyl ether as a commercial refrigerant based on artificial neural networks // Expert Systems with Applications. – 2010. – 37.– pp.7755–7761. DOI: 10.1016/j.eswa.2010.04.065
28. **Kurt H., Kayfeci M.,** Prediction of thermal conductivity of ethylene glycol–water solutions by using artificial neural networks // Applied Energy. – 2009. – 86. – pp.2244–2248. DOI: 10.1016/j.apenergy.2008.12.020
29. **Eslamloueyan R., Khademi M.H.** Estimation of thermal conductivity of pure gases by using artificial neural networks.//International Journal of Thermal Sciences. – 2009. – 48. – pp.1094-1101. DOI: 10.1016/j.ijthermalsci.2008.08.013
30. **Sozen A., Ozalp M., Arcaklioglu E.** Investigation of thermodynamic properties of refrigerant/absorbent couples using artificial neural networks. Chemical Engineering and Processing 2004;43:1253–1264. DOI: 10.1016/S0140-6701(05)80375-3
31. **Sozen A., Arcaklioglu E., Ozalp M.** Formulation based on artificial neural network of thermodynamic properties of ozone friendly refrigerant/absorbent couples. Applied Thermal Engineering 2005;25:1808–1820. DOI: 10.1016/j.applthermaleng.2004.11.003
32. **Sencan A., Yakut K.A., Kalogirou S.A.** Thermodynamic analysis of absorption systems using artificial neural network. Renewable Energy 2006;31:29–43. DOI: 10.1016/j.renene.2005.03.011
33. **Urata S.** et al. Prediction of vapor–liquid equilibrium for binary systems containing HFEs by using artificial neural network // Fluid Phase Equilibria. – 2002. – 199. – pp. 63–78. DOI: 10.1016/S0378-3812(01)00814-7
34. **Artemenko S., Mazur V.** Azeotropy in the natural and synthetic refrigerant mixtures // International Journal of Refrigeration. – 2007. – 30(5). – pp. 831-839. DOI: 10.1016/j.ijrefrig.2006.11.010
35. **Mohanty S.** Estimation of vapour liquid equilibria for the system carbon dioxide–difluoromethane using artificial neural networks. // International Journal of Refrigeration. – 2006. – 29. – pp.243–249. DOI: 10.1016/j.ijrefrig.2005.05.007