

# Идентификация и управление системами вентиляции и кондиционирования воздуха с помощью нейронных сетей

М. Дык Нгуен

Санкт-Петербургский государственный электротехнический университет  
«ЛЭТИ» им. В.И. Ульянова (Ленина)

haduna.hv@gmail.com, milesa58@mail.ru, sana199706@mail.ru

**Аннотация.** В статье показано, что нейронные сети могут эффективно использоваться для идентификации и управления системами вентиляции и кондиционирования воздуха (нелинейная динамическая система). В статье рассматриваются модели как процесса распознавания, так и процесса управления. Обсуждается алгоритм обратного распространения для настройки параметров нейронной сети. В статье вводятся основные понятия и определения, а также описываются некоторые теоретические вопросы, которые необходимо рассмотреть.

**Ключевые слова:** нейронная сеть, идентификация и управление, алгоритм обратного распространения, система вентиляции и кондиционирования воздуха

## I. ВВЕДЕНИЕ

Постоянное развитие науки и техники приводит к появлению более сложных объектов управления. К практическим требованиям относится управление все более сложными динамическими системами в условиях возрастающей неопределенности и более высокие требования к качеству управления. Вышеуказанные требования не могут быть полностью удовлетворены с использованием имеющейся традиционной теории управления. Это движущая сила зарождения новой области исследований — интеллектуального управления. Отличие интеллектуального управления от обычного заключается в том, что при проектировании в принципе не требуется математическая модель объекта управления.

Фактически существует два типа регуляторов: традиционные регуляторы и интеллектуальные регуляторы. К традиционным регуляторам относятся такие регуляторы, как интегральные (И), пропорционально-интегральные (ПИ), пропорционально-интегрально-дифференциальные (ПИД) регуляторы, которые используются для уменьшения отклонения рабочих параметров устройства. Однако при использовании этих контроллеров качество немного ухудшается, например, из-за большой перенастройки и длительного времени отладки, что влияет на стабильность работы системы. Для преодоления этих ограничений в настоящее время широко исследуются и разрабатываются интеллектуальные методы управления, использующие нечеткую логику (НЛ) и искусственные нейронные сети (ИНС). Благодаря использованию интеллектуальных регуляторов качество управления системы было

значительно улучшено и достигло желаемых требований.

Искусственные нейронные сети широко используются в идентификации и управлении, особенно нелинейными объектами. Математическая основа утверждения о том, что нейронные сети являются универсальными аппроксиматорами непрерывных функций, основана на теоремах Стоуна–Вейерштрасса и Колмогорова [1].

В следующем разделе будет представлен объект управления — системы вентиляции и кондиционирования воздуха, а также пояснены некоторые модели как процесса распознавания объектов, так и процесса управления объектами.

## II. РАЗРАБОТКА ОБЪЕКТА УПРАВЛЕНИЯ (СИСТЕМА ВЕНТИЛЯЦИИ И КОНДИЦИОНИРОВАНИЯ ВОЗДУХА)

Объектом управления является система вентиляции и кондиционирования воздуха (рис. 1). Это объект с нелинейными термодинамическими свойствами. Система представляет собой совокупность множества технических устройств (насосов, вентиляторов, компрессоров...), спроектированных и собранных с использованием асинхронных двигателей. Различные режимы работы этих устройств определяют рабочие характеристики всей системы.




Рис. 1. Объект управления

Устройства и оборудование кондиционирования воздуха часто проектируются для работы в наиболее сложных внешних условиях с высокой номинальной нагрузкой, поэтому большую часть времени эти системы технического оборудования работают в режиме низкой нагрузки. Процесс управления работы этих

устройств имеет важное значение, поскольку, если насосы, вентиляторы или компрессоры не отрегулированы должной нормой, система кондиционирования воздуха не будет работать в оптимальном режиме, а её эффективность будет невысокой, что приведет к перерасходу электроэнергии.

### III. ПРИМЕНЕНИЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ В ИДЕНТИФИКАЦИИ И УПРАВЛЕНИИ ОБЪЕКТАМИ

#### A. Многослойная нейронная сеть прямого распространения (МНСПР)

Искусственные нейронные сети (ИНС) можно рассматривать как простые математические модели человеческого мозга. Нейронные сети (рис. 2) состоят из нейронов (каждая ячейка считается процессорной единицей), соединенных друг с другом связями. Каждое соединение сопровождается весом, который характеризует возбуждающие или тормозные свойства между нейронами:




Рис. 2. Искусственные нейронные клетки

Многослойные сети прямого распространения – это сети прямого распространения, состоящие из двух или больше слоев обрабатывающих нейронов. Слой нейронов, подключенных к входу, называется входным слоем (обычно входной слой не выполняет никаких операций обработки); слой нейронов, подключенных к выходу, называется выходным слоем; слой нейронов, не подключенных напрямую к входу и выходу, называется скрытым слоем. Связи между нейронами в слоях могут быть полными или неполными. Алгоритмом обучения многослойных сетей прямого распространения является алгоритм обратного распространения. Алгоритм обратного распространения выполняет два этапа распространения информации. Сначала входной сигнал данных  $x(k)$  передается со входа на выход, результатом передачи данных в прямом направлении является получение выходного сигнала  $y(k)$ . Тогда ошибка представляет собой разницу между  $d(k)$  и  $y(k)$ , которая распространяется обратно из выходного слоя в предыдущий слой для обновления весов сети. Поскольку алгоритм обучения сети прямого распространения представляет собой алгоритм обратного распространения, эта сеть также называется сетью обратного распространения.




Рис. 3. Многослойная нейронная сеть прямого распространения

Алгоритм обратного распространения, используемый для корректировки весов (применительно к трехслойной нейронной сети прямого распространения, как показано на рис. 3), можно обобщить следующим образом:

Шаг 1: Выберите начальные параметры: Скорость обучения  $\eta > 0$ ; Требуемая максимальная ошибка  $E_{\max}$ .

Шаг 2: Запуск алгоритма:

- Установите начальную ошибку  $E = 0$  и  $k = 1$ ;
- Установите начальные значения для весов  $w_{iq}(k), v_{qj}(k)$  ( $i = \overline{1, n}; j = \overline{1, m}; q = \overline{1, l}$ ) любыми малыми натуральными числами.

Шаг 3: (Передача данных в прямом направлении) Рассчитать выход сети с входным сигналом  $x(k)$ :

Скрытый слой:  $q = \overline{1, l}$

$$net_q(k) = \sum_{j=1}^m v_{qj}(k)x_j(k); z_q(k) = a_h(net_q(k))$$

Выходной класс:  $i = \overline{1, n}$

$$net_i(k) = \sum_{q=1}^l v_{iq}(k)z_q(k); y_i(k) = a_o(net_i(k))$$

Шаг 4: Обратное распространение ошибки и обновление весов нейронной сети:

Выходной класс:

$$\delta_{oi}(k) = [(d_i(k) - y_i(k))][a'_o(net_i(k))] \quad i = \overline{1, n}$$

$$w_{iq}(k+1) = w_{iq}(k) + \eta \delta_{oi}(k) z_q(k) \quad i = \overline{1, n}; q = \overline{1, l}$$

Скрытый слой :

$$\delta_{hq}(k) = [\sum_{i=1}^n (\delta_{oi}(k) w_{iq}(k))][a'_h(net_q(k))] \quad q = \overline{1, l}$$

$$w_{qj}(k+1) = w_{qj}(k) + \eta \delta_{hq}(k) x_j(k) \quad j = \overline{1, m}; q = \overline{1, l}$$

Шаг 5: Определите накопленную ошибку:

$$E = E + \frac{1}{2} \sum_{i=1}^n (d_i(k) - y_i(k))^2$$

Шаг 6: Если  $k < K$ , то присваиваем  $k=k+1$  и возвращаемся к шагу 3. Если  $k = K$ , то переходим к шагу 7.

Шаг 7: Завершите цикл обучения. Если  $E < E_{\max}$ , то процесс обучения заканчивается. Если  $E \geq E_{\max}$ , то установите  $E = 0$ ,  $k = 1$  и вернитесь к шагу 3, чтобы начать новый цикл обучения.

Во время обучения сети необходимо учитывать некоторые влияющие факторы:

- Начальные веса: Начальные веса оказывают большое влияние на полученные результаты. Если начальные веса выбраны равными, то правильный результат не может быть получен, если решение алгоритма представляет собой разные веса. Обычно начальные веса выбираются как небольшое случайное значение, поскольку если эти веса слишком велики, функция активации будет насыщена с самого начала и алгоритм попадет в локальные экстремумы.
- Коэффициент обучения  $\eta$  оказывает сильное влияние на скорость обучения и сходимости алгоритма обратного распространения. Невозможно выбрать  $\eta$  соответствующим образом для разных случаев, обычно  $\eta$  выбирается на основе опыта решения каждой задачи. Большое значение  $\eta$  увеличит скорость обучения, но если оно слишком велико, это может привести к тому, что алгоритм не будет сходиться. Напротив, малое значение  $\eta$  гарантирует, что алгоритм всегда сходится, но скорость обучения очень низкая, что приводит к потере времени и памяти компьютера.
- Критерием обучения сети является квадратичная ошибка (сумма квадратов ошибок). Если происходит изменение стандарта обучения, меняется только сигнал обучения. Остальные выражения алгоритма обратного распространения остаются неизменными.
- Правило обновления веса: Метод градиентного спуска — один из простейших методов оптимизации. В качестве альтернативы можно использовать метод Ньютона:

$$w_{ij}(k+1) = w_{ij}(k) - \left[ \frac{\partial^2 E(k)}{\partial w_{ij}^2} \right]^{-1} \left[ \frac{\partial E(k)}{\partial w_{ij}} \right] \quad (1)$$

Преимуществом метода Ньютона является быстрая сходимость, однако он легко попадает в локальные экстремумы. С другой стороны, в (1) вычисление второй производной весьма затруднительно, поэтому на практике этот метод применяется редко.

- Импульс: Мы не всегда можем выбрать желаемый коэффициент обучения  $\eta$ . Метод градиентного спуска может быть очень медленным, если коэффициент обучения слишком мал, и может сильно колебаться, если коэффициент обучения слишком велик. Такое явление часто возникает, если точка минимума имеет форму долины с большим уклоном по бокам и небольшим уклоном в нижней части. Широко используемым эффективным средством, позволяющим получать большие коэффициенты обучения без

расхождения, является добавление импульса к обычному методу градиентного спуска.

$$w_{ij}(k+1) = w_{ij}(k) + \Delta w_{ij}(k)$$

$$\Delta w_{ij}(k) = -\eta \frac{\partial E(k)}{\partial w_{ij}} + \alpha \Delta w_{ij}(k-1) \quad (2)$$

В (2)  $\alpha$  называется коэффициентом импульса ( $0 \leq \alpha \leq 1$ ), значение  $\alpha$  часто выбирается равным 0,9. Благодаря добавленному импульсу каждый вес будет изменяться в направлении среднего наклона, поэтому алгоритм не колеблется.

- Данные для обучения сети должны быть достаточными и правильными. Эксперименты показывают, что данные для обучения сети должны выбираться случайным образом и охватывать все пространство входных сигналов, чтобы в процессе классификации данных не было упущено.
- Количество скрытых узлов: Количество нейронов в скрытом слое существенно влияет на сходимость алгоритма обратного распространения и качество сети. Обычно количество нейронов в скрытом слое выбирается на основе опыта. Рекомендуется начать с сети с небольшим количеством ячеек в скрытом слое. Если алгоритм не сходится, то постепенно увеличивайте количество ячеек, пока алгоритм сходится. Не выделяйте большое количество ячеек в скрытом слое с самого начала.

## В. Применение искусственных нейронных сетей в идентификации объектов

Большинство объектов управления являются нелинейными, более сложными и крайне неопределенными. Нелинейные объекты представлены дискретными моделями, которые делятся на следующие четыре формы [2]:

- Форма 1: Выходной сигнал линейно зависит от прошлых выходных значений  $y(k)$  и нелинейно зависит от прошлых входных значений  $u(k)$ .
- Форма 2: Выходной сигнал линейно зависит от прошлых входных значений  $u(k)$  и нелинейно зависит от прошлых выходных значений  $y(k)$ .
- Форма 3: Выходной сигнал нелинейно зависит от прошлых входных значений  $u(k)$  и нелинейно зависит от прошлых выходных значений  $y(k)$ .
- Форма 4: Выходной сигнал нелинейно зависит от прошлых выходных значений  $y(k)$  и зависит от входных значений  $u(k)$  вместе с его прошлыми значениями.

Объект HVAC принадлежит к форме 4. Он представлен в дискретной форме модели следующим образом (рис. 4):




Рис. 4. Нелинейная модель объекта 4-ой формы

Выходной сигнал определяется следующим выражением:

$$y_p(k+1) = f[y_p(k), y_p(k-1), \dots, y_p(k-n+1); u(k), u(k-1), \dots, u(k-m+1)]$$

Здесь  $y_p(k+1)$  нелинейная зависимость от прошлых выходных значений и зависимость от входных значений вместе с его прошлыми значениями;  $[u(k), y_p(k)]$  являются парами входных-выходных сигналов объекта в момент времени  $k$ , при  $m \leq n$ . Функция  $f(.)$  — неизвестная нелинейная функция объекта, которую необходимо определить с требуемой точностью.

Основным принципом при решении задачи идентификации объекта является построение максимально простой математической модели, что означает выбор простой структуры сети, количество рекуррентных элементов и количество нейронов в скрытом слое должны быть как можно меньше, при условии, что отклонение между выходом сети и выходом идентифицируемой объекта достаточно мало, чтобы быть приемлемым. Диаграмма решения задачи идентификации представлена следующим образом:




Рис. 5. Циклическая диаграмма решения

Могут применяться два метода параллельной идентификации и последовательно-параллельной идентификации (как показано на рис. 6). Преимуществом последовательно-параллельной модели идентификации является более высокая скорость сходимости по сравнению с параллельной моделью идентификации.





Рис. 6. а) Параллельная модель идентификации; б) последовательно-параллельная модель идентификации

### С. Применение искусственных нейронных сетей в управлении объектами

На рис. 7 представлена структурная схема системы управления вентиляцией и кондиционирования воздуха по образцу модели с использованием нейронных сетей: одна нейронная сеть является управляющей, а другая — нейронной моделью идентификации объекта.




Рис. 7. Системы управления по эталонному образцу с использованием нейронной сети

где:  $e_1$  — это разница между выходными данными ИНС-модели и выходными данными объекта, используемого

для обучения сети ИНС-модели;  $e_2$  – отклонение между выходными данными объекта и эталонным образцом, также известное как контрольное отклонение. Эта ошибка используется для обучения сети ИНС-регулятора.

Процесс идентификации объекта сначала выполняется путем поиска ИНС-модели с подходящей структурой, чтобы среднеквадратическая ошибка между ее выходными данными и выходными данными объекта была наименьшей.

Мы объединим эту ИНС-модель с сетью ИНС-регулятора в единую сеть, называемую ИНС-системой, а затем обучим эту нейронную сеть ИНС-системы с помощью набора эталонных входных и выходных сигналов [4], полученных от входных и выходных данных модели образца. Во время обучения параметры ИНС-модели остаются фиксированными, настраиваются только параметры ИНС-контроллера таким образом, чтобы среднеквадратическая ошибка между выходными данными ИНС-системы и модели образца была наименьшей. Схема системы, используемой для обучения регулятора нейронной сети, показана на рис. 8.




Рис. 8. Диаграмма обучения ИНС-регулятора

Таким образом, проектирование нейронного регулятора по сути является проблемой идентификации, а объектом идентификации является эталонная модель управления.

Программное обеспечение Matlab Simulink предоставляет блок инструментов «Model Reference Controller», который включает в себя две нейронные сети [5]: нейронную сеть, используемую для идентификации модели, и нейронную сеть с функцией управления. Изменение параметров в регуляторе поможет упростить конструкцию регулятора на основе первоначальных прогнозов о модели объекта. Он автоматически представляет возмущения и неопределенности модели в виде нейронных сетей с одним скрытым слоем. Затем блок обновляет параметры контроллера в режиме

реального времени, чтобы устранить эти помехи и неопределенности в управляемой системе, устраняя необходимость ручной настройки.

#### IV. ЗАКЛЮЧЕНИЕ

В статье представлен процесс идентификации и управления системами вентиляции и кондиционирования воздуха (нелинейными объектами) с использованием нейронных сетей. Кратко представлены этапы алгоритма обратного распространения при обучении многослойной нейронной сети прямого распространения. В статье показана возможность применения нейронных сетей для идентификации любых нелинейных объектов. Поскольку из структуры видно, что нейронная сеть представляет собой нелинейную систему с множественными входами и множественными выходами (MIMO), и она удобна при управлении объектами со многими переменными. Проблема выбора нейронной сети остается: как выбрать подходящую структуру сети и метод обучения сети. В процессе идентификации и управления следует выбирать максимально простую структуру, но при этом отвечающую требованиям технологии. Применяя нейронные сети для идентификации нелинейных моделей объектов, в результате получается модель объекта в виде нейронной сети, в которой ошибка между нейронной моделью и реальным объектом находится в пределах допустимой ошибки. На основе объектной модели нейронной сети будет спроектирован регулятор с использованием нейронной сети в соответствии с заданной образцовой моделью управления. Динамические и нелинейные свойства нейронного регулятора устраняют нелинейность объекта, благодаря чему система работает как линейная, что является преимуществом по сравнению с некоторыми другими методами управления.

#### СПИСОК ЛИТЕРАТУРЫ

- [1] Nguyen Huu Cong. Research on the application of neural networks in identification and control of robot arms – a nonlinear dynamic object, ISSN 1859-1531 // Journal of science and technology, DaNang University, Vol 5(102).2016, pp. 14-18.
- [2] Narendra K.S., Kannan Parthasarathy. Identification and control of Dynamical Systems Using Neural Networks // IEEE Transactions on Neural Networks, Vol 1, Issue 1, pp. 4-27.
- [3] Pham Huu Duc Duc (2009). Neural networks & applications in automatic control, Science and Technology Publisher, HaNoi, 2009.
- [4] Nguyen Duc Hien, Hoang Dinh Co. Learning materials on fuzzy control and neural networks. Teaching aid, HaNoi, 2019.
- [5] Howard Demuth, Mark Beale, Martin Hagan. Neural Network Toolbox™ User's Guide, Version 9.1 (Release 2016b), The Math Works. 2016.