

Полученный закон управления также обеспечивает выполнение технологического требования к работе системы. Более того является оптимальным по параметру быстродействия системы, так как время установления процесса не превышает 7 минут.

Выводы

Модель системы была реализована с помощью пакета прикладных программ MATLAB, для анализа динамики изменения влажности в теплице. С помощью анализа системы доказали адекватность выведенной динамической системы уравнений, математически описывающей температурный режим в теплице. Проведена серия экспериментов, в том числе и цифровых, по оценке работы модели, а также по определению оптимальных режимов температуры и влажности. Анализ двух методов управления показал, что недорогим и эффективным способом регулирования, является реализация управления с помощью введения в цепь обратной связи ПИД-регулятора. Однако наиболее устойчивым к внешним амплитудным воздействиям и оптимальным по быстродействию оказывается управление, реализованное методом АКАР. В результате проведения исследования разработали модель управления с оптимальными режимами регулирования влажности в крышной теплице.

Список литературы

1. Колесников А.А. Синергетическая теория управления. М.: Энергоатомиздат, 1994. 344 с.
2. Кудинов Ю.И., Пашенко Ф.Ф. Теория автоматического управления (с использованием Matlab и Simulink): учебное пособие. СПб.: Лань, 2018. 312 с.
3. Ziegler J.G., Nichols N.B. Optimum settings for automatic controllers. Trans. ASME. 1942. Vol. 64. P. 759-768.
4. Chien K.L., Hrones J.A., Reswick J.B. On automatic control of generalized passive systems. Trans. ASME. № 74. P. 175-185.
5. Цыпкин Я.З. Основы информационной теории идентификации. М.: Наука, 1984. 320 с.
6. Красовской А.А. Справочник по теории автоматического управления. М.: Наука, 1987. 712 с.
7. Колесников А.А. Синергетические методы управления сложными системами (теория системного синтеза). М.: Едиториал УРСС, 2005. 229 с.

ПРОБЛЕМА ПЕРЕОБУЧЕНИЯ В НЕЙРОННЫХ СЕТЯХ

Губанова А.А., Курган Н.С., Сеницын В.В.

ФГБОУ ВО «Донской государственный
технический университет», Ростов-на-Дону,
e-mail: anatoliya81@mail.ru

Переобучение в машинном обучении в нейронных сетях (НС) представляет собой реальную проблему, которую в настоящее время нельзя полностью избежать. К факторам, образующим эффект переобучения можно отнести такие, как: 1) ограничение размера выборки обучающих данных, возможность их «очистки» от шумов;

2) сложность классификаторов; 3) сложность и многопараметричность обучающих алгоритмов.

Рассмотрим популярные стратегии, которые позволяют действенно устранять явление переобучения:

- стратегия сокращения – сокращает размер заключительных классификаторов в реляционном обучении, за счёт неприменения менее важных и неподходящих данных. Данная стратегия предотвращает явление переобучения и позволяет повысить точность классификаторов;

- стратегия ранней остановки- позволяет предотвратить переобучение путём прекращения обучения за счёт нахождения контрольной точки остановки обучения после определения того, что точность пробных данных перестала улучшаться;

- стратегия расширения данных, заключающаяся в подавлении явления переобучения за счёт грамотной настройки гиперпараметров модели, её адекватной сбалансированностью между точностью и регулярностью обучения. Данная стратегия подразумевает более точно производить настройку параметров при достаточном больших объёмах данных;

- стратегия регуляризации, заключается в конечном выборе только «нужных» функций, влияющих на конечный результат;

- стратегия прореживания (отсева) наиболее популярная стратегия против переобучения в НС [1-3]. Рассмотрим её более детально.

Принцип стратегии прореживания заключается в том, что обучается не одна глубокая нейронная сеть, а целый набор, после чего берутся усреднённые результаты (рис. 1). Из сети выключаются нейроны с такой вероятностью P , что вероятность включения нейрона должна соответствовать условию $d = 1 - P$. Последнее означает, что исключение хотя бы одного из нейронов будет соответствовать обучению новой НС, а исключённый нейрон на входе всегда возвращает значение ноль [4,5].

Таким образом, распределение вероятностей (1):

$$F(P) = \begin{cases} P, & \text{при } \rightarrow k = 1 \\ 1 - P, & \text{при } \rightarrow k = 0 \end{cases}, \quad (1)$$

где k – вероятностные выходные значения.

Из рис. 2. видно, что слои x_1, \dots, x_n НС из N нейронов на каждой итерации этапа обучения можно считать как совокупность распределения Бернулли с вероятностью P . Тогда на выходном слое мы получаем значение исключённых нейронов (2):

$$Y = \sum_{i=1}^N (1 - X_i), \quad (2)$$

где X_i – вектор случайных величин.




Рис. 1. Графическое представление метода прореживания




Рис. 2. Пример многослойной НС




Рис. 3. Пример биномиального распределения

$$Y = \binom{2048}{1024} 0,5^{1024} (1 - 0,5)^{2048 - 1024} \approx 0,05$$

Получается, что вероятность отключения 1024 нейронов составляет 0,05. На рис. 3 представлено распределение значений вероятности выключения нейронов.

Список литературы

1. Хайкин С. Нейронные сети. Полный курс. 2-е изд., испр. М.: Вильямс, 2008. 1103 с.
2. Рутковская Д., Пилинский М., Рутковский Л. Нейронные сети, генетические алгоритмы и нечеткие системы / Пер. с польск. И.Д. Рудинского. 2-е изд., стереотип. М.: Гор. линия – Телеком, 2013. 384 с.
3. Уорр К. Надежность нейронных сетей: укрепляем устойчивость ИИ к обману: практическое руководство. СПб.: Питер, 2021. 272 с.
4. Hinton G.E. et al. Dropout: A Simple Way to Prevent Neural Networks from Overfitting. Journal of Machine Learning Research. 2012. Vol. 15. P. 1929–1958.
5. Метод решения проблемы переобучения в нейронных сетях. URL: <https://habr.com/ru/company/wunderfund/blog/330814/Dropout>.

Исходя из (2) видно, что если слой состоит из 2048 нейронов и взяв $P = 0,5$, то видно, что 1024 из них будет выключено, т.е.: