

НЕЙРОННАЯ МОДЕЛЬ ВОЗДУХООБМЕНА В ЖИЛЫХ ПОМЕЩЕНИЯХ

1. Введение

Общую концепцию применения нейронных сетей для задач воздухообмена представлено впервые в статье [1]. Оценены таким образом численные значения кратности воздухообмена дают возможность решения некоторых микроклиматических и энергетических задач, имеющих место в здании [2], особенно в области технической диагностики и предвидения. Одновременно, однако, появилась проблема определения некоторой сетевно-информативной стандартизации, использованной при решении поставленной задачи. Это связано не только с возможностью доступа к разному, типовому для нейронных сетей программному обеспечению [3], но также с выполнением существенных анализов и сравнительных и верификационных исследований при использовании искусственных нейронных сетей в моделировании процесса воздухообмена. Слишком индивидуальные решения в области сетевой логики [1] не имеют возможности быстрого распространения и внедрения. Существенным является создание универсальной сети с архитектурой учитывающей зависимости и сопряжения проходящее во время протекания воздуха, с возможностью эвентуальной пристройки новых связей и подбора к ним стандартного программного обеспечения.

В статье принята попытка выбора типовых необходимых параметров для учета в архитектуре сети, оптимально отражающей ход процесса воздухообмена. Анализ касался протекания воздуха в области помещения. На этой основе разработана модель, простая для выполнения и распространения с помощью доступного программного обеспечения.

2. Представление вводных данных

Исследования и измерения процесса воздухообмена в помещении характеризуют случайные и контролируемые параметры [2]. На основе анализа опытных данных, их влияния на окончательную величину

воздухообмена, взаимосопряжения и взаимовоздействия, определены следующие вводные данные для структуры сети:

- п1: K_n — угол потока ветра относительно стены комнаты, $^\circ$,
- п2: T — разница наружной и внутренней температур, К,
- п3: W — скорость ветра, м/с,
- п4: P — разница давлений внутри и снаружи помещения, Па,
- п5: K — номер этажа на котором проведено измерение (безразмерное),
- п6: I — частное суммы длины щелей в наружных столярных изделиях к объему помещения, м/м³,
- п7: V — объем помещения, м³,
- п8: W — коэффициент воздухопроницаемости наружных столярных изделий согласно пределам, м³/(мчПа^{0.7}): 0.5: 0.5 ÷ 0.8, 1.0: :0.9 ÷ 1.2, 2.0: 1.8 ÷ 2.4, 3.0: 2.7 ÷ 3.2.

В качестве переменной состояния процесса принята кратность воздухообмена в помещении N в ч⁻¹. Группу случайных (климатических) условий представляют переменные п1 ÷ п4, контролируемых (проектных) параметров, переменные п5 ÷ п8. Установлены 3 варианта моделирования: для высоких зданий 8 ÷ 11 — этажных, средних 5 — этажных и низких объектов (односемейных) 1—2 этажных.

Проанализированы три следующие способы представления обучающих данных на вводах сети:

- данные представленные последовательно, записанные в базе данных в очередности класс,
- данные представленные последовательно, записанные в базе данных в случайной очередности,
- данные представленные в вероятностной очередности.

На основе практических опытов кажется, что последний из перечисленных способов представления данных является наиболее оптимальным, так как в наибольшей степени дает возможность избежания “блокирования” сети в невыгодном местном минимуме. При этом способе сложным однако является пользование очевидным в случае последовательного обучения критерием завершения расчетов, каким является падение суммарной квадратной погрешности на выходах сети ниже заданной величины. Ход кривой погрешности становится неравномерным и зависит от того, какие картины были поданы на входы сети в данном цикле обучения. Второй метод дает равномерные кривые обучения, но, однако, риск несовпадения процесса обучения является большим. В случае первого метода может оказаться, что картины записанные в первой очередности в базе данных преобладают над остальными, эффектом

чего является неспособность сети к выработке правильных ответов для дальнейших классов. В крайних случаях это ведет к патологическому состоянию, когда очередность записи данных в обучающей базе определяет решаемость проблемы.

В исследуемой нейронной модели кратности обмена воздуха испробованы три метода и не обнаружена существенная разница из-за применяемого метода. В связи с этим принят третий метод как наиболее распространенный и гарантирующий избежание решений типа местного минимума.

3. Архитектура сети

Чаще всего в задачах нейронного моделирования употребляются рекуррентные сети Хопфилда или более простые сети типа перцептронного со встречным распространением погрешности [4]. Эта последняя является типичной статической сетью, но путем условного расширения входного и выходного вектора моделируемого объекта о значениях в прежних моментах, получается эффект динамического сохранения. Окончательно для моделирования инфильтрации и расчетов кратности воздухообмена в помещении принята перцептронная сеть с алгоритмом обучения путем встречного распространения погрешности.

Общий вид алгоритма обучения, позволяющий на итерационную модификацию весовых множителей для отдельных слоев на основе вычисленных в предыдущей величине погрешностей, определяет выражение:

$$\delta_i^{(L)} = -\frac{\partial E}{\partial o_i^{(L)}} = (t_i - o_i^{*(L)}) \cdot (f(F(o_i^{(L)})))' \quad (1)$$

(для выходного слоя L),

$$\delta_i^{(l)} = \sum_k \delta_k^{(l-1)} \cdot w_{ki}^{(l+1)} \cdot (f(F(o_i^{(l)})))' \quad (2)$$

(для любого скрытого слоя l),

где E — является значением текущей погрешности обучения, t_i — является целевым значением обучения для выхода i , o_i — обозначает соединенную путем взвешенного суммирования входную информацию элемента обработки (PE_i), o_i^* — выходной сигнал (PE_j), w_{ki} — связь весовых множителей, $(f(F))'$ — обозначает производную функции перехода (PE), которая является эффектом сложения функции выхода $f()$ и активации $F()$.

Окончательно, изменение веса Δw_{ij} для любого слоя не являющегося выходным слоем, может быть записанным как:

$$\Delta w_{ij}^{(l)} = \eta \cdot \delta_i^{(l)} \cdot o_j^{*(l-1)}, \quad (3)$$

где η является коэффициентом обучения. В одном процессе алгоритма, веса изменяются по зависимости:

$$w_{ij}^{(t+1)} = w_{ij}^{(t)} + \Delta w_{ij}, \quad (4)$$

где t обозначает время.

Рост величины η позволяет на ускорение обучения, но увеличивает осцилляцию весовых множителей и может привести к дестабилизации этого процесса. Для противодействия в появлении чрезмерных осцилляций весовых множителей при слишком больших значениях коэффициента обучения η введен выравнивающий коэффициент α :

$$w_{ij}^{(l+1)} = w_{ij}^{(l)} + \Delta w_{ij}^{(l)} + \alpha \cdot \Delta w_{ij}^{(l-1)}. \quad (5)$$

Анализ сетевых структур, на основе протекания явления воздухообмена, позволил выбрать двухслойную модель, с одним скрытым слоем состоящим из 4 нейронов. Увеличивание как количества слоев, так и количества нейронов в скрытом слое не влияет на точность полученных результатов, но значительно увеличивает время преобразования и обучения сети, а также увеличивает требования к оборудованию для проведения расчетов. Структуру связей сети представляет рис. 1.




Рис. 1. Структура сети

В скрытом слое помещены следующие нейроны:

n_1 — давление ветра; n_2 — количество статического давления; n_3 — взвешенная сумма значений давлений; n_4 — нейрон учитывающий “производительность” щелей в столярке помещения. В выходном слое нейрон n_1 определяет кратность воздухообмена в помещении.

4. Верификация модели

Исследования показали, что сеть после 100 тыс. обучающих циклов достигала момента, в котором не осуществлялось улучшение получаемых величин. Дальнейшие исследования влияния количества циклов заключающиеся в увеличении количества обучающих циклов доказали, что сеть во время обучения проходит циклически между значениями двух минимумов очень взаимно приближенных. При расчетах точности и соответствия полученных результатов число 100 тыс. циклов оказалось оптимальным и дальнейшие исследования проводились на основе того же числа повторений обучающего цикла.

Проверку проведено на основе рассчитанных среднеквадратических отклонений величин, получаемых в модельных исследованиях по отношению к измеряемым величинам. Полученные результаты представлены в графиках на рис. 2 а, б, в, соответственно для малых, средних и высоких объектов.




Рис. 2а. Полученные результаты измерения (n_o) и расчета (n_p) для малых зданий

Диагональ графика представляет 100% соответствие между величинами полученными на основе нейронной модели, и полученными в измерениях. Заметным является высокое соответствие полученных результатов. При больших величинах кратности обменов имеет место

постоянная погрешность между моделью, и измеряемыми величинами. Из представленной на графиках величины линии направления вытекает, что погрешность эту легко исключить путем введения поправочного коэффициента определенного из разницы линии направления и значения $y = x$.




Рис. 2б. Полученные результаты измерения (n_o) и расчета (n_p) для средних зданий




Рис. 2в. Полученные результаты измерения (n_o) и расчета (n_p) для высоких зданий

Значения полученных среднеквадратических отклонений для отдельных зданий представляет таблица. Среднеквадратичные погрешности ниже 15% в представляемых моделях являются результатами очень хорошими, выполняющими требование решающей модели, описывающей характер явления обобщенным способом.

Значения среднеквадратических отклонений

№ пп.	Тип здания	Среднее количество этажей	Среднеквадратическое отклонение
1	Малое	2	11,9 %
2	Среднее	5	13,3 %
3	Высокое	11	14,1 %

5. Выводы

- Представленная архитектура сети является структурально простой и возможной для реализации стандартными программами для нейронных расчетов.
- Полученное среднеквадратическое отклонение на уровне 14% положительно верификует нейронную модель для применения в исследованиях воздухообмена.
- Возможным является расширение разработанной сети для задач протекания воздуха в пространстве всего здания.

Использованная литература

1. *Piotrowski J.*, Neural Network Application for Air Exchange. The 6-th International Conference on Air Distribution in Rooms, Stockholm, 1998, Vol. 1, p. 311—316.
2. *Piotrowski J.*, Air Exchange through Elements of Building Partition. The 7-th International Conference on Indoor Air Quality and Climate, Nagoya, 1996, Vol.3, p.827—832.
3. *Zurada J.*, Introduction to Artificial Neural System. West Publishing Company, 1992.
4. *Iiguni Y., Sakai H., Tokumaru H.*: A nonlinear regulator design in the presence of system uncertainties using multilayered neural networks. IEEE Transactions on Neural Networks, Vol. 2, No. 4, 1991.