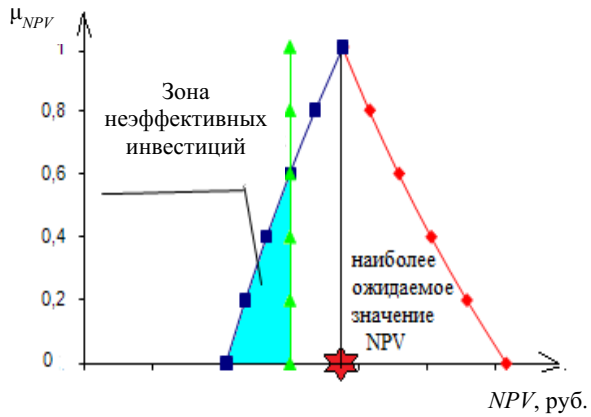


Рис. 3. Оценка чистого дисконтированного дохода и риска инвестиций

Литература

1. *Аншелес, В.Р.* О некоторых вопросах стратегической синергии в производстве промышленной продукции / В.Р. Аншелес, И.Л. Вишнякова, Е.О. Быкова // Материалы восьмой международной научно-технической конференции «Автоматизация и энергосбережение машиностроительного и металлургического производств, технология и надежность машин, приборов и оборудования». – Вологда, 2013. – С. 19 – 21.
2. *Вишнякова, И.Л.* Метод и алгоритмы обработки информации в системе поддержки принятия решений процесса получения защитной азотно-водородной атмосферы в производстве метизов: дис. … канд. техн. наук / И.Л. Вишнякова. – Череповец, 2011.
3. *Игонина, Л.Л.* Инвестиции / Л.Л. Игонина. – М., 2004.
4. *Кемпбелл, Э.* Стратегический синергизм / Э. Кемпбелл, К. Саммерс Лачс. – СПб., 2004.
5. *Коссов, В.В.* Методические рекомендации по оценке эффективности инвестиционных проектов / В.В. Коссов, В.Н. Лившиц, А.Г. Шахназаров. – М., 2000.

УДК 621.313.2:681.513.7:004.896

В.Н. Волков, А.В. Кожевников

РАЗРАБОТКА НОВОГО МЕТОДА ДИАГНОСТИРОВАНИЯ АВТОМАТИЗИРОВАННЫХ ЭЛЕКТРОМЕХАНИЧЕСКИХ СИСТЕМ ПРОКАТНЫХ СТАНОВ С ПОМОЩЬЮ НЕЙРОСЕТЕВЫХ АЛГОРИТМОВ

В работе рассмотрен способ оценки состояния электрических приводов, основанный на построении нейросетевой модели. На примере электропривода постоянного тока описан эксперимент, показывающий эффективность данного способа. Может найти применение для диагностики состояния электроприводов прокатных станов металлургического производства.

Электропривод постоянного тока, нейронная сеть, идентификация динамических объектов, системы управления.

The article describes the method of evaluation of electrical drives based on the construction of neural network models. On the example of a DC motor the experiment is described showing the effectiveness of this method. The method can be used for diagnostics of electric drives for steel rolling mills.

DC drive, neural network, identification of dynamic objects, control systems.

В настоящее время применение микропроцессорной техники поспособствовало «интеллектуализации» оборудования. Яркий пример тому – электрические приводы, представляющие собой системы, способные к самонастройке, самодиагностике и адаптации. Подобные системы получают все большее распространение в качестве приводной техники для высокопроизводительных линий. В металлургической промышленности автоматизированный электрический привод применяется в подавляющем большинстве установок и технологических комплексов. До половины всей потребляемой металлургическими предприятиями электроэнергии приходится на электроприводную технику.

Особые требования в металлургии предъявляются к автоматизированным электроприводам листовых непрерывных прокатных станов. Там традиционно применяются электроприводы постоянного тока с независимым возбуждением, имеющие хорошие эксплуатационные показатели в условиях динамических нагрузок и способные обеспечить плавное регулирование скоростей в широких диапазонах.

Как и любые другие технические устройства, электроприводы прокатных станов нуждаются в обслуживании. При этом качество эксплуатации электроприводов и эффективное планирование ремонтных и наладочных работ косвенно влияют на такие показатели производства, как: производительность стана, качество проката и себестоимость продукции. Оптимальная настройка системы управления позволяет снизить потребление электрической энергии станом и исключить брак, а своевременное обнаружение неисправности на начальной стадии позволяет избежать дорогостоящего ремонта и простоя всего стана.

Существующие системы автоматического управ-

ления электроприводами непрерывных листовых прокатных станов способны оперативно обнаруживать и локализовать возникновение аварийных ситуаций. К таким ситуациям можно отнести неполадки в преобразовательной технике, электродвигателях или механической части. Однако обнаружение неисправности системой автоматики часто происходит на той стадии, когда разрушения значительны и требуют существенных ремонтов.

Такие предвестники неполадок, как колебательный характер скорости, ухудшение качества переходных процессов, старение подшипниковых узлов или механических передач, не фиксируются датчиками в начальной стадии. Обнаружить их в настоящее время могут только квалифицированные специалисты, используя соответствующие приборы и аналитические экспертные методы. Они анализируют совокупность признаков в работе оборудования по данным с различных приборов и способны оценить всю динамику процессов. Хороший специалист по анализу осциллограмм переходных процессов может практически сразу определить, когда оборудование находится в предаварийном состоянии или требует переналадки. При этом расходы на профилактический ремонт будут существенно ниже, чем в ситуации, когда неисправность приобретет явный характер, который будет зафиксирован системой автоматики. Однако при том количестве электроприводной техники, которая используется в прокатном производстве, невозможно физически отслеживать состояние оборудования силами квалифицированных специалистов в полном объеме и оперативно.

Другое решение состоит в модернизации оборудования, приобретении оборудования, способного к интеллектуальной обработке информации. Но подобное оборудование имеет высокую стоимость и переход всего парка электроприводов на подобные системы невозможен.

В вышеприведенной ситуации целесообразным выглядит разработка относительно недорогих и универсальных технических решений, способных производить диагностику состояния электропривода прокатных станов, в постоянном режиме оценивая динамику работы клетей.

Цель данной работы – разработка концепции нового метода диагностики автоматизированных приводов прокатных станов, работающих в условиях повышенных динамических нагрузок. Он основан на применении методов искусственного интеллекта – нейросетевых алгоритмов для идентификации электроприводов с последующим анализом отклонения динамики. Такой способ позволяет получить прогноз о его техническом состоянии на основании текущей информации о переходных процессах.

В качестве объекта исследования выбран электропривод клети листового стана непрерывной прокатки.

В рамках данной работы были поставлены следующие задачи:

1) получение параметров электропривода в динамике;

2) выбор архитектуры нейронной сети и ее обучение;

3) моделирование процесса идентификации и диагностики.

Если рассмотреть электрический привод как динамический объект, описываемый вектором входных данных, вектором внутреннего состояния и вектором выходных данных, то, согласно теореме об универсальной аппроксимации [2], [10], искусственная нейронная сеть может идентифицировать его при наличии достаточного количества обучающих данных. В промышленных электроприводах применяется большое количество датчиков, поэтому получение входных и выходных векторов возможно.

В источниках [4], [8], [10] приводятся способы нейросетевой идентификации обобщенных динамических объектов. Имеется достаточно много публикаций по данной тематике [2], [3], [11]. Однако мало публикаций по нейросетевой идентификации конкретных динамических объектов, таких как электрический привод [1], [2]; большинство же работ имеют обзорный характер. Некоторую сложность применения искусственных нейронных сетей представляет разработка архитектуры сети под конкретный класс объектов и подбор обучающих данных. До сих пор эта задача не формализована, имеются лишь общие рекомендации и эмпирические данные [7], [8], [10].

При построении и исследовании электропривода применялись системы моделирования динамических процессов *Simulink* и *SimPowerSystems* среды разработки *Matlab*. Для моделирования в библиотеке *SimPowerSystems* выбран электродвигатель постоянного тока независимого возбуждения со следующими параметрами: $R_я$ = 0,78 Ом, $L_я$ = 0,016 Гн, $R_в$ = 150 Ом, $L_ф$ = 112,5 Гн, $U_я$ = 240 В, $U_в$ = 150 В, W = 195 рад/с, соответствующий электродвигателю клети листового прокатного стана. Преобразователь для упрощения модели представлен регулируемым блоком напряжения, имеющим задержку $\frac{1}{T_n s + 1}$ на входе по управлению.

Для решения первой задачи требовалось получить необходимый набор данных работы электропривода в динамике. Количество обучающих примеров должно быть достаточным, чтобы описать работу системы во всех реальных рабочих режимах. В реальных электроприводах имеется возможность получения подобной информации, либо непосредственно с датчиков, либо с управляющих микропроцессорных средств. При моделировании в *Matlab* использовался сигнал случайного процесса, сгенерированный при помощи стандартного блока *Simulink*. При этом, согласно [10], чем больше информации, тем точнее будет отображение. В данном эксперименте сигнал подавался в течении t = 240 с на входное задание $U_{вх}$ и на вход нагрузки $M_н$. Одновременно снимались выходы по скорости W и току якоря $I_я$. Информация с обмотки возбуждения не учитывалась, предполагая работу только в первой зоне по

скорости. Данные были приведены к безразмерному виду для удобства обучения сети.

При решении второй задачи – выборе архитектуры нейронной сети – необходимо учитывать динамику процесса, т.е. сеть должна «помнить» предыдущие состояния объекта. Для этих целей, как правило, применяются обратные связи от выходных сигналов нейронной сети к ее входам [10], [11]. Построение обобщенной архитектуры подобных сетей описано в источниках [8], [10], [11]. В данной работе была использована нейронная сеть с задержками в обратных связях, известная как модель нелинейной регрессии с внешними входами *NARX* и описанная в [6], [10]. Она получается из обычного многослойного персептрона путем введения обратных связей с задержкой. Подобная архитектура важна при запоминании последовательностей сигналов. Обобщенная модель имеет следующую формулу:

$$\overline{y}(n+1) = \varphi\left(\overline{y}(n),\ldots,\overline{y}(n-q+1)\right), \\ \overline{u}(n),\ldots,\overline{u}(n-q+1)\big),$$

где $\overline{y}(n)$ – выходной вектор, $\overline{u}(n)$ – входной вектор, n – дискретный момент времени, q – порядок системы.

Применение задержки z^{-1} в обратной связи позволяет устранить проблему устойчивости сети [1], [10]. На рис. 1 приведена структура сети *NARX*.

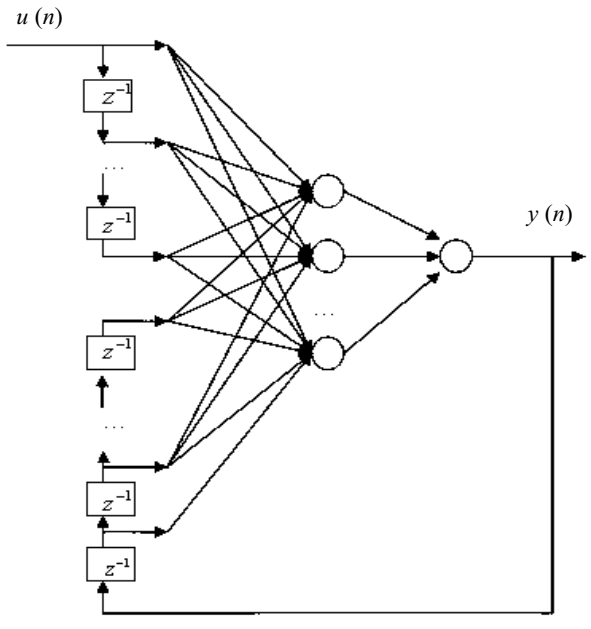


Рис. 1. Рекуррентная нейронная сеть *NARX*

В настоящее время нет точной методики выбора числа нейронов внутреннего слоя, эвристически же было получено оптимальное число нейронов в количестве 5. При большем числе нейронов внутреннего слоя возрастает скорость обучения, однако, падает способность к аппроксимации нейронной сетью новых данных [6], [10]. При малом числе нейронов сеть может не обучиться с достаточной точностью.

Во внутреннем слое сети применена гиперболическая тангенциальная функция активации, имеющая формулу:

$$\text{tansig}(N) = \frac{2}{1+e^{2N}} - 1,$$

где $N = \sum_{j=0}^{J} U_j \cdot W_{ij}$ – сумма произведений входного вектора и весовых коэффициентов первого слоя.

В выходном слое задана линейная функция активации, линейно отображающая сигнал на выход:

$$\text{purelin}(N) = N,$$

где N – сумма произведений выходов нейронов внутреннего слоя на весовые коэффициенты выходного слоя.

Для обучения сети использовался алгоритм Левенберга-Марквардта, реализующий обучение посредством подстройки весовых коэффициентов нейронной сети в зависимости от погрешности выхода сети и обучающего множества [6]. Обучение производилось в течение 300 итераций, при этом ошибка обучения составила $ErrL = 7 \cdot 10^{-5}$.

Решение третьей задачи было разделено на несколько этапов. Сначала было произведено сравнительное моделирование при неизменных параметрах электропривода, имитировавшее нормальный режим работы. После этого имитировались изменения рабочих параметров, свидетельствовавшие о нарушениях в работе электропривода, и моделирование повторялось.

Так, наиболее распространено нарушение целостности изоляции якорной цепи: перегрев двигателя или плохой контакт в коллекторе вызывают изменение сопротивления и индуктивности якорной цепи, при этом меняется динамика работы всей клети. Если своевременно не отследить этот процесс, то он приводит к перегреву двигателя и его выходу из строя. Кроме того моделирование показало, что изменение сопротивления якорной цепи снижает эффективность системы управления, вызывая колебательный процесс. Это связано с тем, что классические системы подчиненного регулирования не способны компенсировать изменение больших постоянных времени в широких пределах и настройка коэффициентов регуляторов становится неэффективной [9]. Разработанный метод диагностики позволяет выявить этот дефект на ранней стадии.

Другой распространенный вид нарушений связан с разрушением подшипниковых узлов или редуктора. Это приводит к изменению момента инерции, колебательному процессу, усилению вибраций, что также ведет к разрушению механической части. Моделирование показало, что данная проблема также может быть диагностирована предложенным мето-

дом на ранних стадиях, не приводящих к сильным разрушениям.

Для моделирования в *Simulink* была собрана схема, состоящая из электропривода постоянного тока, эквивалентного тому, что используются в листовых непрерывных прокатных станах и его обученной нейросетевой модели [4]. Для стабилизации скорости W в схему был включен пропорционально-интегральный регулятор, настроенный для электропривода клети и скопированный для нейросетевой модели. Моделирование производилось в течении t = 30 с. Имитировалась работа клети прокатного стана по следующему алгоритму, соответствующему реальным условиям эксплуатации:

– валки разгонялись до скорости захвата металла на 5 с;

– происходил захват металла на 8 с;

– клеть разгонялась до рабочей скорости на 12 с;

– металл покидал клеть на 22 с;

– остановка клети на 25 с.

При проверке нейросетевой модели параметры электропривода были в норме и соответствовали тем, что были при обучении нейросетевой модели. На рис. 2 изображен результат моделирования, где при одинаковых входных воздействиях отображена динамика электропривода и его нейросетевой модели.

Погрешность отклонения динамики нейросетевой модели от динамики электропривода рассчитана по формуле:

$$Err = \frac{1}{N}\sum_{i}^{N}\left(W_{neyr} - W_{drive}\right)^2,$$

где Err – среднеквадратичное отклонение, W_{neyr} – вектор изменения скорости нейросетевой модели, W_{drive} – вектор изменения скорости электропривода, N – размерность вектора.

Для нормального режима работы среднеквадратичная погрешность составила $Err = 2,4 \cdot 10^{-5}$, что говорит о высокой точности нейросетевой модели и из графиков видно, что они практически совпадают.

На следующем этапе были внесены изменения, характерные для предаварийных ситуаций в электроприводе прокатного стана. Имитировалось изменение сопротивления якорной цепи двигателя вследствие нарушений в изоляции. Результаты моделирования при измененном сопротивлении якорной цепи приведены на рис. 3. Система регулирования уже не могла полностью скомпенсировать постоянную якорной цепи и заметен колебательный процесс. На графике отчетливо видно отклонение динамики электропривода от его нейросетевой модели во время переходных процессов. При достижении уставок задающего воздействия и при изменении момента сопротивления наблюдалось перерегулирование скорости и колебательный процесс с затуханием. Среднеквадратичная погрешность резко увеличилась и составила $Err = 3,8$. Подобные отклонения позволяют судить о расхождении динамики модели и объекта, в том числе реализовать возможность контроля за динамикой электропривода.

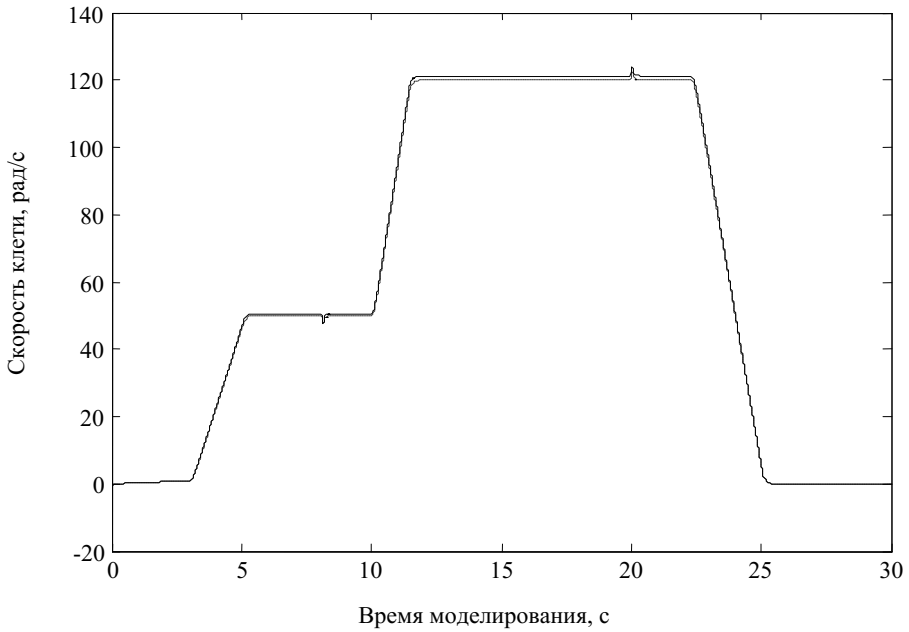


Рис. 2. График сравнительного моделирования скоростей модели реального электропривода и нейросетевой модели при неизменных параметрах электропривода, имитирующих нормальный режим работы

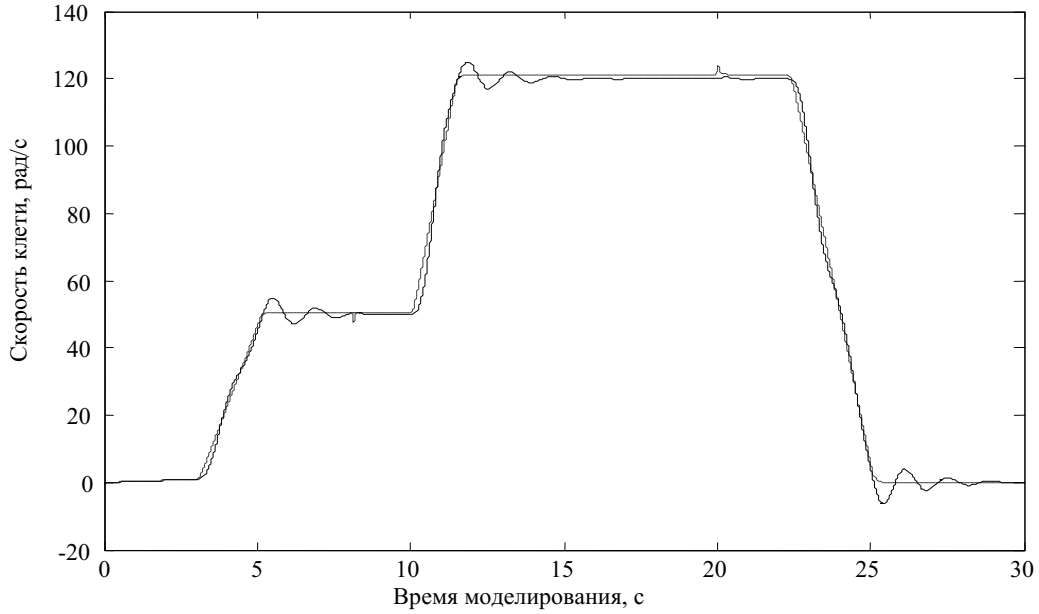


Рис. 3. График сравнительного моделирования скоростей модели реального электропривода и нейросетевой модели при изменении момента инерции на валу двигателя, имитирующем нарушение в механической части

Подобный колебательный процесс в реальных условиях не будет зафиксирован системой автоматики, так как параметры или их производные будут в пределах допусков. Но несвоевременное обнаружение ведет к быстрому износу и разрушению рабочих узлов оборудования из-за колебательных процессов. Кроме того, ухудшается качество системы управления. Если оперативно обнаруживать подобное отклонение, то можно получить экономию по двум статьям:

– ремонт потребует меньше финансовых затрат в связи с тем, что неисправность будет локализована до того, как повлечет за собой крупные поломки;

– ремонт займет меньшее время, если неисправность локализована на ранней стадии.

Разработанный метод диагностирования позволяет взять на себя функцию контроля за динамикой скорости и предупреждать отклонения в работе оперативно. Проведены положительные испытания в лабораторных условиях на разработанных математических моделях. Математические модели показали свою адекватность при имитации различных нарушений, таких как:

– разрушение подшипниковых узлов электродвигателя;

– заклинивание редуктора и системы валков клети;

– нарушение целостности обмоток якоря;

– износ щеточного аппарата в коллекторе;

– перегрев электродвигателя;

– ухудшение качества системы управления.

На следующем этапе исследования планируется создание в лабораторных условиях опытного образца устройства, реализующего разработанный метод диагностики, и проверка степени его адекватности на реальном электроприводе в рамках экспериментальных исследований для оптимизации разработанных алгоритмов.

Подобными системами диагностики в перспективе могут быть оснащены все автоматические электропривода объектов металлургической промышленности. Система не требует существенных капитальных затрат и высокой квалификации обслуживающего персонала для внедрения и эксплуатации. При этом она может быть реализована как в виде дополнительного блока, работающего в фоновом режиме, так и в виде дополнительного кода в программном обеспечении имеющихся контроллеров. Кроме этого, применение рассмотренного в данной работе метода вполне может быть расширено и применено к другим типам электроприводов металлургического производства, а так же к иным техническим устройствам и агрегатам для оценки их состояния.

Литература

1. *Волков, В.Н.* Нейросетевая идентификация электропривода постоянного тока / В.Н. Волков, А.В. Кожевников // Современные научные исследования и инновации. – 2013. – Апрель. – URL: http://web.snauka.ru/issues/2013/04/23648

2. *Горбань, А.Н.* Обобщенная аппроксимационная теорема и вычислительные возможности нейронных сетей / А.Н. Горбань // Сибирский журнал вычислительной математики / РАН. Сибирское отделение. – Новосибирск, 1998. – Т. 1. – № 1. – С. 11 – 24.

3. *Клепников, В.Б.* Применение методов нейронных сетей и генетических алгоритмов в решении задач управ-

ления электроприводами / [В.Б. Клепников и др.] // Электротехника. – 1999. – № 5. – С. 2 – 6.

4. *Кожевников, А.В.* Диагностирование приводов прокатных станов с помощью нейросетевой оценки / А.В. Кожевников // Металлургические процессы и оборудование. – № 3(33). – 2013. – С. 54 – 60.

5. *Макаров, И.М.* Интеллектуальные системы автоматического управления / И.М. Макаров, В.М. Лохин. – М., 2001.

6. *Медведев, В.С.* Нейронные сети. MATLAB6 / В.С. Медведев, В.Г. Потемкин. – М., 2002.

7. *Оссовский, С.* Нейронные сети для обработки информации / С. Оссовский; Пер. с польского И.Д. Рудинского. – М., 2002.

8. *Терехов, В.А.* Нейросетевые системы управления / В.А. Терехов, Д.В. Ефимов, И.Ю. Тюкин. – М., 2002.

9. *Терехов, В.М.* Системы управления электроприводов / В.М. Терехов, О.И. Осипов. – М., 2006.

10. *Хайкин, С.* Нейронные сети: полный курс / С. Хайкин. – М., 2006.

11. *Чернодуб, А.Н.* Обзор методов нейроуправления / А.Н. Чернодуб, Д.А. Дзюба. – URL: http://ailen.org/.

УДК 533.697

М.Л. Зайцева, Н.И. Корнилов, Э.Н. Сабуров

СОПРОТИВЛЕНИЕ ОТНОСИТЕЛЬНО ДЛИННЫХ ЦИКЛОННЫХ КАМЕР ПРИ РАЗЛИЧНЫХ УСЛОВИЯХ ВВОДА И ВЫВОДА ГАЗОВ

Установлены характерные особенности зависимости суммарного коэффициента сопротивления относительно длинных циклонных камер в приближенно автомодельной области течения от величины относительного диаметра выходного отверстия и относительной площади входа камеры. Предложено эмпирическое уравнение для расчета коэффициента сопротивления относительно длинных циклонных камер.

Относительно длинная циклонная камера, суммарный коэффициент сопротивления, площадь входа, диаметр выходного отверстия, число Рейнольдса.

The characteristic features of the dependence of the summary resistance coefficient of relatively long vortex chambers in approximately self-flow region from the relative diameter of the orifice and the relative area of the camera input are determined. An empirical equation to calculate the resistance of relatively long vortex chambers is proposed.

Relatively long vortex chamber, total coefficient of resistance, entrance area, the outlet diameter, the Reynolds number.

Сопротивление циклонной камеры любого технологического назначения в значительной степени определяет ее энерготехнологическое совершенство [1], [2]. Поэтому разработка рекомендаций по расчету их сопротивления представляет большой теоретический и практический интерес. Выполненные в настоящее время экспериментальные работы, связанные с определением сопротивления циклонных камер, в основном относятся к камерам сравнительно небольшой относительной длины $\overline{L_к} = L_к / D_к$ ($L_к$ – длина, $D_к$ – диаметр рабочего объема циклонной камеры) равной 0,8…2. Число исследований сопротивления циклонных камер большой относительной длины ($L_к > 2$) значительно меньше. Однако такие камеры имеют широкое использование в химической и целлюлозно-бумажной промышленности в качестве печей, рекуператоров, теплообменников, сепараторов и других устройств. Исследование, результаты которого приведены в настоящей работе, выполнено на экспериментальном стенде с циклонной камерой, имевшей относительную длину 12,75. Диаметр ее рабочего объема составлял 160 мм. Его поверхность была технически гладкой. Относительная площадь входа камеры $\overline{f_{вх}} = 4 f_{вх} / \pi D_к$ ($f_{вх}$ – суммарная площадь тангенциальных шлицев) варьировалась в диапазоне от 0,04 до 0,21. Относительный диаметр выходного отверстия $\overline{d_{вх}} = d_{вх} / D_к$ ($d_{вх}$ – размерный диаметр соосного с рабочим объемом выходного отверстия камеры) − от 0,2 до 1,0.

На рис. 1 представлены полученные в опытах при различных значениях параметра $\overline{d}_{вх}$ и числах Рейнольдса ($\mathrm{Re}_{вх} = \upsilon_{вх} D_к / \nu$, где ν – кинематический коэффициент вязкости потока при входных условиях) значения суммарного коэффициента сопротивления рассматриваемой камеры:

$$\zeta_{вх} = \frac{2\Delta P_п}{\rho \upsilon_{вх}^2},$$

где $\Delta P_п$ − перепад полного давления в камере – разность полных давлений в шлицах и на выходе из камеры; ρ – плотность потока на входе в камеру (в шлицах); $\upsilon_{вх}$ – среднерасходная скорость потока в шлицах.