

Прикладное применение комплексных нейронных сетей

Сергей Куликов

На сегодняшний день нейронные сети имеют очень широкое распространение по всему миру. Они также используются во всех сферах деятельности человека и вместе с этим принесли новый способ обработки, анализа и прогнозирования данных.

Введение

Алгоритмы обучения оказали огромное влияние на многие области компьютерных наук и нашли множество применений в различных областях, таких как компьютерное зрение, биоинформатика, передвижение роботов и распознавание речи. Эти алгоритмы избегают ручного решения конкретных проблем, предпочитая вместо этого «учиться» и адаптироваться в соответствии с набором примеров, называемых обучающим набором.

Алгоритм обучения состоит из грубой модели и метода настройки параметров в соответствии с обучающим набором. Нейронные сети являются примером такой модели. Они состоят из множества взаимосвязанных простых вычислительных блоков, комбинация которых приводит к сложной функции. Эта модель была впервые представлена в 1940-х годах и периодически изучалась в последующие годы.

Мы же рассмотрим вариацию модели СНН (свёрточная нейронная сеть) с комплексными входными параметрами. Комплексные числа уже давно доказали свою полезность для обработки изображений (например, преобразование Фурье является комплексным) и были рассмотрены в контексте, свя-

занном с нейронной сетью. Например, эффекты синхронизации существуют в человеческом мозге и, как предполагается, играют ключевую роль в зрительной системе. Такие эффекты отсутствуют в основных реализациях нейронных сетей. Так или иначе, комплексные нейронные сети имеют большое значение в наше время.

В этой работе предлагается вариация модели свёрточной нейронной сети (СНН) с комплексными входными параметрами.

Основная часть

Предпосылки работы

На данный момент практическое применение комплексных нейронных сетей не ограничивается одним коротким списком. Существует множество причин, по которым комплексные сети сильно востребованы.

Во многих областях применения, таких как беспроводная связь или обработка звука, где комплексные числа возникают естественным образом, существует корреляция между реальной и мнимой частями сложного сигнала. Такие задачи можно решить только используя области частот, для определения которых потребуется комплексная нейронная сеть, обычная веще-

ственная не подойдёт. Также на данный момент нет другого метода для описания фазовых явлений без комплексных чисел.

Если значение величины и фазы для цели обучения известны априори, то разумнее использовать комплекснозначную модель, поскольку в ней ограничений вводится больше, чем в модели с реальным значением.

Также комплексные нейроны превосходят вещественные тем, что они могут обучаться линейно в N-мерном пространстве, в котором они определены. Это очень важно, так как позволяет обойтись без нелинейных проекций на пространство, которое определено с большей размерностью.

А если оценить эффективность обучения одного нейрона, вещественного и комплексного, то победит в этом сравнении комплексный нейрон. Это связано с тем, что функциональность одного комплексного нейрона намного больше, нежели у вещественного. Поэтому комплексная нейронная сеть того же размера, что и вещественная, будет обучаться быстрее.

Основная идея

Комплекснозначная или просто комплексная нейронная сеть (КНС) – это сеть, которая основывается на комплексных числах: комплексными являются входные данные, веса и функция активации.

Процесс обучения с комплексным методом (backpropagation) предметной области аналогичен процессу обучения

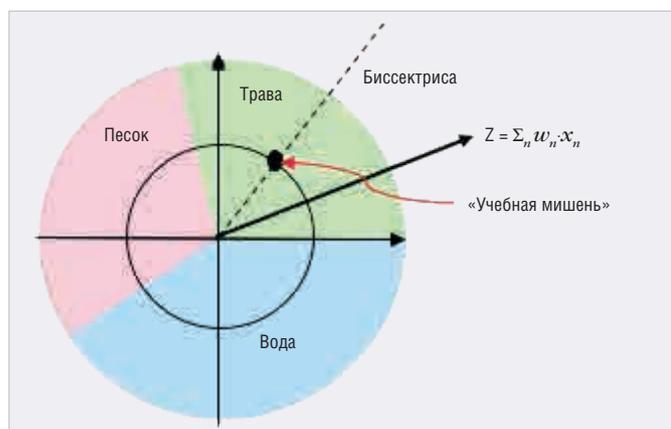


Рис. 1. Пример комплексной функции активации

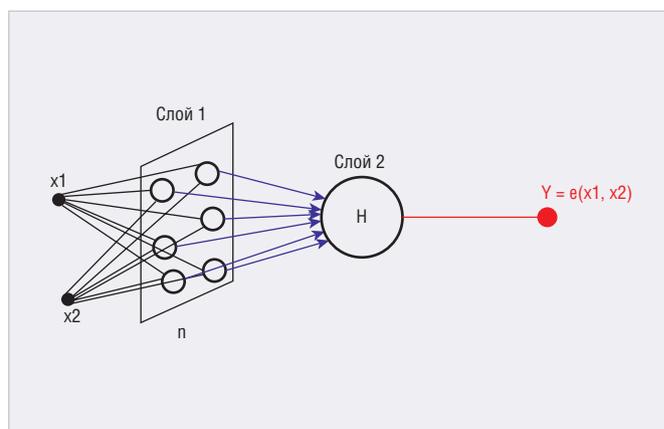


Рис. 2. Схематичное отображение составляющих искусственной КНС Фурье

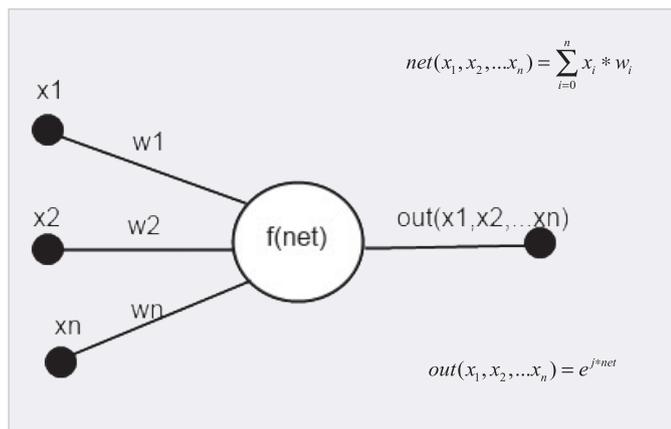


Рис. 3. Схема отдельного комплексного нейрона скрытого слоя

в реальной предметной области. Также ошибка, вычисленная после прохода (forward pass) НС, передаётся обратно каждому нейрону в сети, а веса корректируются в обратном проходе.

Рассмотрим комплексную модель как обобщение вещественных СНН, которая обрабатывает комплексные входные данные и веса. Также разберём простой пример преимущества комплексных нейронных сетей над обычными.

Методика работы

Для упрощения преобразований будут использованы в примере следующие методы.

1. Преобразования Фурье.
 2. Разложение функций в ряд Фурье (формулы):
- комплексный ряд Фурье от одной переменной:

$$f(x) = \sum_{n=-\infty}^{\infty} C_n \times e^{inx}; \quad (1)$$

- формула ряда Фурье от двух независимых переменных:

$$f(x_1, x_2) = \sum_{m, n=-\infty}^{\infty} C_{m, n} \times e^{j(m x_1 + n x_2)}. \quad (2)$$

Общая формула ряда Фурье для функций от «k» переменных:

$$f(x_1, x_2, \dots, x_k) = \sum_{n_1, \dots, n_k=-\infty}^{\infty} C_{n_1, \dots, n_k} \times e^{j \sum_{i=1}^k n_i x_i}. \quad (3)$$

3. Прогнозирование временных рядов с заданной точностью.

Одна из первых работ по описанию комплексной функции активации была выполнена Наумом Айзенбергом. Согласно его концепции, многозначный нейрон (МН) – это нейронный элемент с n входами и одним выходом, лежащим на единичном круге (пример на рис. 1), и с комплекснозначными весами. Отображение описывается следующим образом:

$$(x_1, \dots, x_n) = f(w_0 + w_1 x_1 + \dots + w_n x_n). \quad (4)$$

Здесь x_i – это комплексные переменные.

Краткое содержание

В литературе нет единого мнения о наиболее подходящей функции активации для КНС. Основное требование состоит в том, чтобы иметь нелинейную функцию, которая не подвержена взрыву или исчезновению градиентов во время обучения.

Если взять функцию сигмовидной активации прямого распространения (forward pass), то окажется, что она неоптимальна для многих видов прикладных задач. Возьмём пример распознавания двоичных растровых изображений с использованием преобразований Фурье.

После таких преобразований изображение будет инвариантным к следующим трансформациям: изменению положения, изменению размера и вращению, что позволит нам правильно обучить комплексную нейронную сеть.

В результате расчётов получается комплексный вектор.

Другой пример – прогноз временных рядов с определённой точностью. Сети прямого распространения с функцией сигмоидальной активации не позволяют предсказать ошибку по количеству скрытых нейронов. Чтобы предсказать эту ошибку, потребуется использовать некоторый ряд для скорости сходимости, для которой уже выведены формулы расчёта. В этом примере будет использоваться в качестве такового ряд Фурье.

Архитектура

Разберём архитектуру КНС, её слои, веса и их смысл.

На изображении (рис. 2) схематично показываются составляющие искусственной КНС Фурье. После входных данных x_1, x_2, \dots, x_n находится скрытый слой, который является, по сути, матрицей из $m \times n$ комплексных нейронов. Где m – это кол-во дескрип-

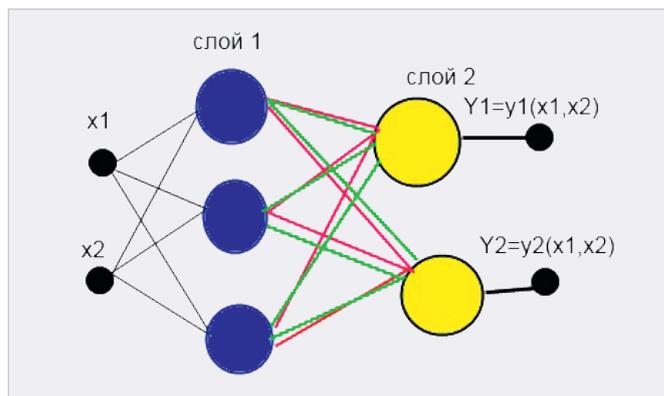


Рис. 4. Результат составления матрицы КНС с уменьшенным количеством нейронов

тов (нормированные коэффициенты в результате преобразования Фурье), а n – это размер вектора входных данных.

На рис. 3 показана схема отдельного комплексного нейрона скрытого слоя. Где x_i – входные данные, w_i – веса, $f(net)$ – функция активации, $out(x_i)$ – выходные данные.

Веса, расположенные в первом слое, подразумевают под собой физический смысл частот, а веса, расположенные во втором, имеют значение коэффициентов для ряда Фурье. Следовательно, количество входов для каждого нейрона в выходном слое равно $m \times n$, что совпадает с количеством коэффициентов для ряда Фурье.

Оптимизация структуры

Само создание матрицы – затраты большого количества вычислительных ресурсов. Но мы сможем уменьшить количество нейронов в скрытом слое в n раз. Тогда каждый нейрон в скрытом слое имеет n выходов, если в КНС n входов. Это приводит к изменению количества связей, и именно оно уменьшается в n^2 раз без потери качества аппроксимации функций. Результат составления такой матрицы комплексной нейронной сети можно увидеть на рис. 4.

Принцип работы КНС

Разберём работу этой КНС, записанной в матричной форме (формуле).

Матричная запись функций активаций комплексных нейронов, расположенных в скрытом слое, показана в выражениях 5...7.

$$f(x) = \sum_{n=-\infty}^{\infty} C_n \times e^{inx} \quad (5)$$

$$f(x_1, x_2) = \sum_{m, n=-\infty}^{\infty} C_{m, n} \times e^{j(m x_1 + n x_2)} \quad (6)$$

$$f(x_1, x_2, \dots, x_k) = \sum_{n_1, \dots, n_k=-\infty}^{\infty} C_{n_1, \dots, n_k} \times e^{j \sum_{i=1}^k n_i x_i} \quad (7)$$

```

public class KNN_Simple {
    ComplexVector input; // Вход
    ComplexVector output; // Выход
    fOut; // Выход скрытого слоя
    Matrix fl; // Матрица весов первого слоя
    ComplexMatrix C; // Матрица весов второго слоя
    int inpN, outpN, hN, n = 0;
    Complex J = new Complex(0, 1); // Мнимая единица

    // Конструктор
    public KNN_Simple(int inpCout, int outpCout, int hLCount) {
        inpN = inpCout;
        outpN = outpCout;
        hN = hLCount;
        // Инициализация весов случ. образом
        fl = Statistic.rand(inpN, hN);
        C = Statistic.randComplex(inpN * hN, outpN);
    }

    // Вектор-функция активации первого слоя
    public ComplexVector functionActivate1Layer(ComplexVector
    compVect) {
        ComplexVector outp = compVect.Copy();
        for (int i = 0; i < outp.N; i++) {
            outp.Vектор[i] = Complex.Exp(J * outp.Vектор[i]);
        }
        return outp;
    }

    // Выход первого слоя
    void OutputFirstLayer(ComplexVector inp) {
        input = inp;
        fOut = functionActivate1Layer(inp * fl);
    }

    // Выход второго слоя
    void OutputOutLayer() {
        List<Complex> outList = new List<Complex>();
        for (int i = 0; i < inpN; i++) {
            outList.AddRange(fOut.Vектор());
        }
        ComplexVector outVector = new ComplexVector(outList.ToArray());
        output = fOut * C;
    }

    // Отклик КНС на входной вектор и возврат результата прохода
    public ComplexVector NetworkOut(ComplexVector inp) {
        OutputFirstLayer(inp);
        OutputOutLayer();
        return output;
    }
}
    
```

Рис. 5. Код полученной комплексной нейронной сети

В этих выражениях n является размером входного вектора x , m – это размер выходного вектора скрытого слоя y_{-1} , f – вектор-функция активации, j – это мнимая единица, w – это матрица весов, k – кол-во выходов КНС.

Пример использования

Возьмём, к примеру, классификацию фотографий.

Перед тем как приступить к распознаванию, лучше применить алгоритмы бинаризации, чтобы решение было приведено к общему виду, после чего вектор полностью подаётся в КНС. В нашем случае с сигмоидальной функцией активации вещественная и мнимая составляющие подавались отдельно, после чего вектор распознавался.

Использовались нейронные сети двух типов: сеть прямого распространения с сигмоидальной функцией активации и КНС.

В результате объём полученной обучающей выборки составил 660 комплексных векторов, разделённых на 33 класса, что соответствует количеству символов кириллицы.

Перейдём к самой реализации на языке программирования.

Полученные результаты

Код полученной комплексной нейронной сети показан на рис. 5.

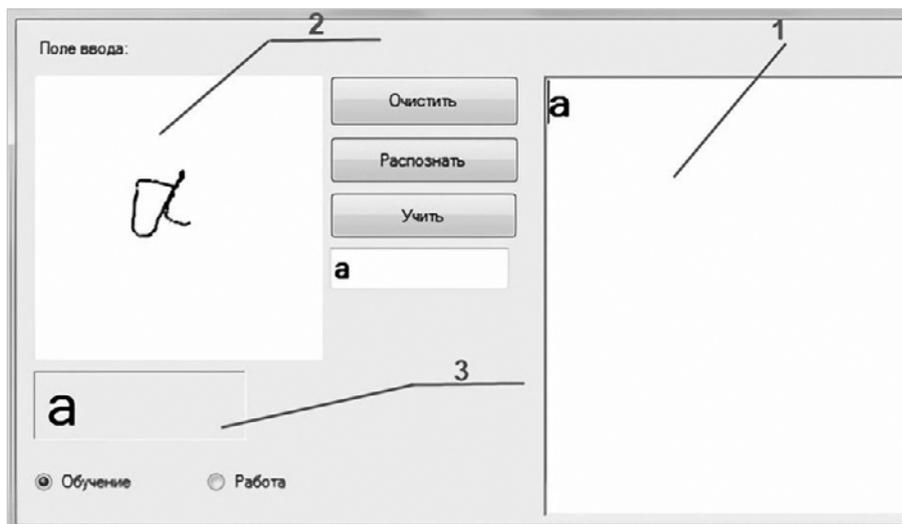


Рис. 6. Графический интерфейс для использования КНС, созданный на С#

Разработан класс KNN_Simple, в котором реализованы следующие методы:

- KNN_Simple – параметризованный конструктор, на вход: количество входных нейронов, количество выходных нейронов и количество нейронов скрытого слоя соответственно;
- functionActivate1Layer – функция активации первого слоя;
- OutputFirstLayer – получение результата активации первого слоя;
- OutputOutLayer – вывод последнего (выходного) слоя;
- NetworkOut – проход (forward pass) и вывод результата прохода.

Для использования написанной комплексной нейронной сети использовался набор данных из открытого доступа, предусмотрен графический интерфейс, созданный на С# (рис. 6). Элементы интерфейса: 1 – поле распознанных символов, 2 – поле для рисования символа, 3 – поле распознанного символа.

Кнопки: «Очистить» – очищает рисунок, «Распознать» – распознаёт рисунок, «Учить» – если сеть неправильно дала ответ, нужно скорректировать значение и нажать на эту кнопку для обучения.

Заключение

Даны определения комплексным нейронным сетям (КНС). Доказана необходимость КНС на разных прикладных примерах. Проведены этапы разработки нейронной сети и её работы, реализация её кода на языке программирования С#.

Достоинства КНС

Комплексная нейронная сеть имеет огромную сферу прикладного применения: её можно использовать для работы с сигналами, заданными в

комплексном виде, также она очень хорошо подойдёт для распознавания бинарных изображений. Она может аппроксимировать функцию, оставляя все свойства преобразования Фурье, что делает её работу легко анализируемой. Ведь именно неанализируемость работы нейронных сетей приводит к тому, что в научных проектах от них иногда отказываются, решая задачи другими методами. Также физический смысл весов позволит использовать эту нейронную сеть для численного разложения функции многих переменных в ряд Фурье. Разновидность применений комплексных нейронных сетей сильно растёт, особенно в последнее десятилетие.

Недостатки КНС

Существенным недостатком данной нейронной сети является наличие большого количества связей, намного превышающего количество связей сетей, основанных на вещественных числах.

Литература

1. Фихтенгольц Г.М. Курс дифференциального и интегрального исчисления. Т. 3. М.: ФИЗМАТЛИТ, 2001.
2. Осовский С. Нейронные сети для обработки информации / пер. с польск. И.Д. Рудинского. М.: Финансы и статистика, 2004.
3. Brouwer Friso C.G., Tingdabl Kristofer M., Connolly David. A guide to the Practical Use Of Neural Network // URL: https://www.researchgate.net/publication/289828233_A_Guide_to_the_Practical_Use_of_Neural_Networks.
4. Guberman N. On Complex Valued Convolutional Neural Networks // URL: <https://deeppai.org/publication/on-complex-valued-convolutional-neural-networks>. ©

Цифровизация натурального эксперимента

Елизавета Каширская

В статье рассмотрена возможность и преимущества аналитического эксперимента по сравнению с натурным. Приведены два примера проведения аналитического эксперимента с последующим вычислительным этапом в качестве иллюстрации цифровизации аналоговой информации.

Введение

Часть экологической сферы Земли, содержащую технические, созданные людьми сооружения, принято называть техносферой. Цифровая трансформация техносферы включает в себя множество независимых процессов, одним из которых является замена натурального эксперимента вычислительным. Но даже в условиях цифровизации невозможно полностью отказаться от натуральных экспериментов при проектировании новых технических объектов и полностью перейти на проведение вычислительных экспериментов. Причина состоит в том, что вычислительный эксперимент всегда носит дискретный характер, в то время как моделируемые процессы по большей части являются непрерывными.

Основная часть

В процессе жизненного цикла промышленного изделия необходимо проводить различные виды экспериментов и испытаний, как над производимым изделием, так и над технологическим оборудованием. Подобные испытания достаточно трудоёмки и продолжительны, что серьёзно увеличивает сроки ввода нового изделия в производство, а также приводит к росту себестоимости изделия, особенно в условиях многономенклатурного мелкосерийного производства.

Достаточно большое количество производственных испытаний тре-

бует определения граничных условий эксплуатации производственного оборудования и не требует более точных параметров. При этом натурные испытания элементов технологического оборудования требуют продолжительного времени и существенных ресурсов. Не всегда удаётся получить все требуемые параметры из-за физических ограничений по съёму данных с измерительных преобразователей. Таким образом, возникает необходимость замены классических натуральных экспериментов цифровыми.

Существует множество классификаций экспериментальных исследований. Эти классификации отличаются основанием деления на типы. По типу моделей, используемых в эксперименте, всевозможные эксперименты обычно разделяют на материальные и мыслительные (или мысленные).

Мы предлагаем несколько отличающуюся классификацию, не противоречащую ГОСТ [7] и Международному стандарту [8], представленную на рис. 1.

Рассматриваем три типа экспериментов. Опыт, в соответствии с [1], принято называть воспроизведение исследуемого явления в определённых условиях. Качественный эксперимент устанавливает только факт существования какого-либо явления, но при этом не даёт никаких количественных характеристик объекта исследования [9]. Количественный эксперимент [9] не только фиксирует факт существования того или иного явления, но и позволяет установить соотношения между количественными характеристиками явления и количественными характеристиками способов внешнего воздействия на объект исследования.

Количественные эксперименты можно подразделить на три вида. При натурном моделировании применяется довольно сложная методика планирования эксперимента с последующей громоздкой статистической обработ-

кой результатов проведения эксперимента. Несомненным преимуществом натурального моделирования является возможность охвата всего диапазона изменения параметров процесса или технического устройства.

При проведении вычислительного (компьютерного) эксперимента в силу его дискретности испытатель не может быть уверен в том, что им охвачены все возможные значения параметров и условий. Вполне возможна ситуация, при которой какие-то критические значения факторов могут оказаться не кратными шагу изменения параметров, в силу чего компьютерная программа получения результатов расчёта их может «проскочить».

В том случае, когда задача проектирования может быть полностью решена аналитически, необходимости в проведении экспериментов не возникает, но существует огромный класс задач, не поддающихся аналитическому решению, но допускающих упрощённое теоретическое решение с последующим получением по построенной модели числовых данных для любых возможных наборов параметров модели. Такой вид получения результатов исследования назовём аналитическим экспериментом.

Почему же подобное исследование мы называем аналитическим экспериментом, а не аналитическим расчётом? Дело в том, что при классическом аналитическом расчёте должны применяться известные или вновь создаваемые теоретические модели исследуемой системы. Мы же ведём речь о том, чтобы вместо теоретических (обоснованных и доказанных) моделей применять приближённую схему, абстрагирующуюся от целого ряда параметров системы, в целях быстрого получения результата. Использование подобного метода допустимо, если его сопровождать обширным вычислительным экспериментом, охватывающим значительную выборку входных параметров системы.

Вычислительный эксперимент, проводимый непосредственно после аналитического, позволяет с помощью большого разброса исходных данных получить цифровую картину исследуемого объекта, явления или процесса. Такое совокупное исследование мож-



Рис. 1. Классификация экспериментальных исследований

но считать аналитико-вычислительным экспериментом.

Аналитико-вычислительный эксперимент (аналитический эксперимент, завершающийся вычислительным, то есть числовым экспериментом) может служить характерным примером цифровизации аналоговой информации.

Аналитический эксперимент, завершающийся вычислительным (числовым) экспериментом, является характерным примером цифровизации аналоговой информации.

Рассмотрим два примера проведения аналитического эксперимента.

Определение толщины стенок вакуумного баллона

Баллон представляет собой замкнутую оболочку, рассчитать напряжения и деформации которой – очень непростая задача из области теории оболочек. По этой причине обычно вместо расчёта с использованием зубодробительных формул проводится натурный эксперимент. Но для получения числовых результатов в любом диапазоне изменения параметров можно применить упрощённую схему расчёта, тем самым оцифровав аналитическое решение. Вакуумный баллон можно представить как цилиндр, на который со всех сторон действует внешнее давление p , Н/м² (рис. 2а).

Возьмём для примера вакуум 10^{-5} мм ртутного столба, что соответствует давлению порядка 10^{-8} атмосфер:

$$\frac{10^{-5}}{760} = 1,32 \times 10^{-8} \text{ атм} = 0,00134 \text{ Па.}$$

Пусть диаметр баллона составляет 80...100 мм (рис. 2б). Объём баллона будем считать равным 1800 см³, что соответствует высоте примерно от 20 до 30 см.

Максимальное нормальное напряжение в стенках баллона определяется по формуле

$$\sigma_{max} = \frac{pR}{\delta}, \text{ Па,} \quad (1)$$

где p – избыточное атмосферное давление на стенки баллона, Па,

R – радиус баллона, м,

δ – толщина стенок баллона, м.

Нужно без проведения натурного эксперимента определить минимальную толщину стенок баллона. Из формулы (1) получим:

$$\delta = \frac{pR}{[\sigma]},$$

где $[\sigma] = \frac{\sigma_m}{n}$ – допустимое нормальное напряжение в стенках баллона, Па,

σ_m – предел текучести материала, Па,

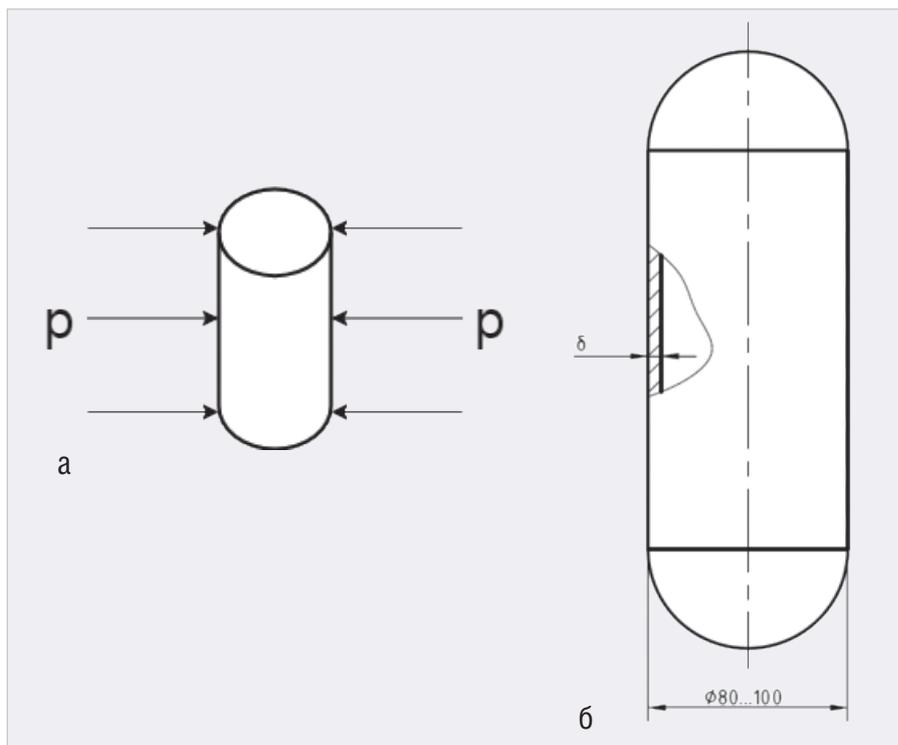


Рис. 2. Вакуумный баллон: а) схематичное представление, б) баллон в разрезе

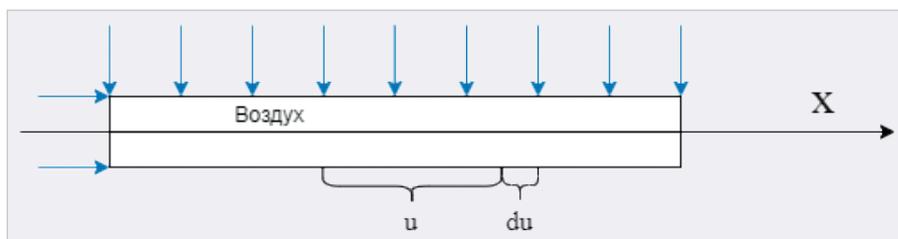


Рис. 3. Воздушный стержень

$n = 1,5$ – коэффициент запаса прочности по пределу текучести.

Для стали 40Х, рекомендуемой для изготовления резервуаров, $\sigma_m = 355 \text{ Н/мм}^2 = 3,55 \times 10^8 \text{ Па}$. В результате получим, что возможно использование тонкостенного баллона, толщина стенок которого может колебаться от 1,5 до 3 мм.

Таким образом, с помощью приближённых аналитических исследований (аналитического эксперимента) и числовых подсчётов удалось получить значение толщины стенок баллона, не прибегая к сложным законам теории оболочек и без проведения эксперимента. А взяв в качестве входных данных большой массив значений радиуса, давления и марок материала, мы можем получить цифровую картину изменения толщины стенок баллона в зависимости от исходных данных.

Воздушный стержень

Рассмотрим замкнутый объём воздуха под давлением, так называемый воздушный стержень (рис. 3).

Осевая сила, действующая на объём воздуха, находится по формуле:

$$N = EF \frac{\partial u}{\partial x},$$

где E – модуль упругости, Па,

F – площадь поперечного сечения, м²,

x – горизонтальная координата, м,

u – длина элементарного объёма воздуха, м,

$\frac{\partial u}{\partial x}$ – скорость перемещения объёма воздуха, м/с.

Давление на единицу площади поперечного сечения:

$$p = \frac{N}{F} = E \frac{\partial u}{\partial x}$$

при квадратном сечении со стороной 2 м $F = 2 \times 2 \text{ м}^2$.

Перемещение элементарного объёма воздуха:

$$U(x,t) = \sum_{n=1}^{\infty} \int_0^t V_0 X_n dx X_n \sin \omega_n t,$$

где V_0 – начальная скорость,

$X_n = \cos k_n x$ – n -я гармоническая составляющая перемещений,

$k_n = \frac{\pi(2n-1)}{2l}$ – закон изменения номеров гармоник,

$\omega_n = k_n \sqrt{\frac{E}{\rho}}$ – собственная частота n -й гармоники колебаний,

E – объёмный модуль упругости воздуха,

$\rho = 1,28 \text{ кг/м}^3$ – плотность воздуха при нормальных условиях,

t – время, с.

Так как $a = \sqrt{\frac{E}{\rho}}$ – скорость перемещения, то

$$p = E \frac{\partial u}{\partial x} = -\sum_{n=1}^{\infty} \frac{2V_0 \sin k_n l E}{\omega_n l} \sin k_n x \sin \omega_n t,$$

где $a_0 = 340 \text{ м/с}$.

Так как $E = \rho a^2$, при давлении в 1 атм (101 325 Па) и при скорости распространения упругих волн в воздухе (скорость звука в воздухе) $a_0 = 340 \text{ м/с}$ получим

$$E = 1,28 \times 340^2 = 147,9 \times 10^3 \text{ Н/м}^2 = 14,8 \text{ Н/м}^2$$

при давлении в 10 атмосфер (1 013 250 Па):

$$E = 64 \times 340^2 = 7,4 \times 10^6 \text{ Н/м}^2 = 740 \text{ Н/см}^2.$$

Так можно вычислить объёмный модуль упругости воздуха при разных условиях.

При $x = l$

$$p = p_{\max} = \sum_{n=1}^{\infty} \frac{2EV_0}{\omega_n l} \sin \omega_n t = \sum_{n=1}^{\infty} \frac{2EV_0 \sin \omega_n t}{\pi(2n-1) \sqrt{\frac{EF}{m_0}}},$$

где $m_0 = \rho F$ – масса единицы длины воздушного объёма. Тогда

$$p_{\max} = \sum_{n=1}^{\infty} \frac{4V_0}{\pi} \sqrt{\frac{m_0 E}{F}} \times \frac{\sin \omega_n t}{2n-1} = \frac{4V_0}{\pi} \sqrt{\frac{m_0 E}{F}} \times \left(\frac{\sin \omega_1 t}{1} + \frac{\sin 3\omega_1 t}{3} + \dots + \frac{\sin n\omega_1 t}{n} + \dots \right).$$

В итоге получим

$$p_{\max} = \frac{4V_0}{\pi} \times \frac{\pi}{4} \sqrt{\frac{m_0 E}{F}} = V_0 \sqrt{E\rho} = V_0 a \rho,$$

где

$$\begin{cases} a = f(p, t) \\ \rho = f_1(p, t) \end{cases}$$

При нормальных условиях $a = 340 \text{ м/с}$, $V_0 = 3000 \text{ м/с}$, $\rho = 1,28 \text{ кг/м}^3$ получим $p = 1,37 \times 10^5 \text{ Н/м}^2$.

Итак, при давлении, пропорциональном 10^5 Н/м^2 , и массе воздуха примерно 3 кг получим ускорение $3,3 \times 10^4$. Тогда

время и скорость перемещения воздуха при длине трубы 2 м составят соответственно:

$$t = \sqrt{\frac{2S}{a}} = \sqrt{\frac{2 \times 2}{3,3 \times 10^4}} = 1,1 \times 10^{-2} \text{ с},$$

$$V = 3,3 \times 10^4 \times 1,1 \times 10^{-2} = 363 \text{ м/с}.$$

Итак, с помощью приближённых аналитических исследований (аналитического эксперимента) и числовых подсчётов удалось получить значение скорости и времени перемещения воздуха в воздушном стержне, не прибегая к сложным теоретическим зависимостям и без проведения эксперимента. А взяв в качестве входных данных большой массив размеров, давления и других исходных данных, мы можем получить цифровую картину изменения результатов расчёта в зависимости от входных параметров.

Приведённые примеры наглядно демонстрируют простоту проведения аналитического эксперимента по сравнению с натурными опытами.

Заключение

Современные тенденции рынка требуют от промышленных предприятий всё большей гибкости к номенклатуре производимых изделий, что, в свою очередь, требует минимизации времени ввода в производство новых изделий. Предлагаемый подход замены части натуральных экспериментов и испытаний на цифровые позволит существенно решить задачу уменьшения времени как на разработку новых изделий, так и на технологическую подготовку производства. Предложенный подход является неотъемлемой частью цифровой трансформации производства.

Литература

1. Холопов В.А., Антонов С.В., Курнасов Е.В., Каширская Е.Н. Разработка и применение

цифрового двойника машиностроительного технологического процесса // Вестник машиностроения. 2019. № 9. С. 37–43.

2. Холопов В.А., Гаиц И.С., Антонов С.В. Применение информационных технологий при решении задач мониторинга выполнения производственных процессов в концепции Индустрии 4.0 // Промышленные АСУ и контроллеры. 2019. № 4. С. 49–58.

3. Панайоти В.А., Мешков В.В., Курнасов Е.В. Технология снижения температуры при шлифовании быстрорежущей стали // Вестник машиностроения. 2020. № 1. С. 68–72.

4. Чижиков В.И., Курнасов Е.В. Математическая модель взаимодействия двух роботов при синхронном выполнении совместной работы // Вестник машиностроения. 2020. № 7. С. 11–15.

5. Холопов В.А., Каширская Е.Н., Шмелева А.Г., Курнасов Е.В. Интеллектуальная система мониторинга выполнения машиностроительных технологических процессов // Проблемы машиностроения и надёжности машин. 2019. № 5. С. 98–112.

6. Холопов В.А., Каширская Е.Н., Соколов Ф.В., Сухастерин А.Б. Информационно-управляющая система для управления технологическим процессом посредством цифрового двойника // Промышленные АСУ и контроллеры. 2020. № 8. С. 46–50.

7. ГОСТ 24026-80 Исследовательские испытания. Планирование эксперимента. Термины и определения. Библиографическое описание. М.: Изд-во стандартов, 1991. 70 с.

8. Международный стандарт ИСО 8402 Управление качеством и обеспечение качества. Словарь. М.: Изд-во стандартов, 1994. 20 с.

9. Чубинский А.Н., Русаков Д.С., Батырева И.М., Варанкина Г.С. Методы и средства научных исследований. СПб., 2018. 109 с.



НОВОСТИ МИРА

Роскосмос: создание и запуск 380 спутников в рамках проекта «Сфера» обойдётся в 180 миллиардов рублей

Из этой суммы на ближайшие три года заложен 21 миллиард рублей, – написано в журнале.

Сейчас финансирование проекта многоспутниковой орбитальной группировки «Сфера» предполагает, что в течение 2022–2024 годов на проект будет выделяться по семь миллиардов рублей ежегодно.



Всего на орбиту будут выведены около 380 спутников. В систему войдут семь аппаратов «Экспресс», четыре «Экспресс-РВ», 12 спутников «Скиф» для широкополосного

доступа в интернет и 264 спутника «Марфон» для Интернета вещей. Также в «Сферу» войдут два спутника связи «Ямал», три спутника ДЗЗ «Смотр», 84 спутника оптического наблюдения «Беркут-О» (обзорный), «Беркут-С» (среднего разрешения) и «Беркут-ВД» (высокодетаальный), 12 аппаратов радиолокационного наблюдения «Беркут-Х» и «Беркут-XLP». Развёртывание всех группировок планируется начать в 2025 году.

www.ixbt.com