

ОТАЛ СПЕКТРАЛ ХАРАКТЕРИСТИКАЛАРИНИ ОПТИМАЛЛАШ БЎЙИЧА ЭКСПЕРИМЕНТАЛ МАЪЛУМОТЛАРНИ НЕЙРО-НОРАВШАН МОДЕЛЛАШТИРИШ

Д.А.Давронбеков¹, З.Т.Хакимов², Ж.Д.Исроилов³

^{1,3}Муҳаммад ал-Хоразмий номидаги Тошкент ахборот технологиялари университети
²Олий таълимни ривожлантириш тадқиқотлари ва илғор технологияларни татбиқ этиш маркази
E-mail: ¹d.davronbekov@gmail.com, ²rmxat@edu.uz

Аннотация -Бу ишда экспериментал маълумотларни аппроксимасиялаш масалалари кўриб чиқилган. Кўрсатилганки, аппроксимасиялаш моделини танлашда мавжуд усулларга қараганда норавшан усулларни қўлланишининг афзаллиги формаллаштирилмаган ёки ёмон формаллаштирилмаган масалаларни йечишдаги натижавийлик, кўп ҳажмли зид маълумотлар билан ишлашдаги натижавийлик, тўлиқ бўлмаган маълумотлар билан ишлашдаги натижавийлик ҳисобланади. Регрессион модел, Сугено норавшан билимлар базаси ва нейро-норавшан модел қўлланиши билан ОТАЛнинг спектрал чизиқларини тадқиқ қилиш бўйича экспериментал маълумотларни аппроксимасиялаш бажарилган.

Калит сўзлар - аппроксимасиялаш, регрессион модел, Сугено норавшан билимлар базаси, спектрал чизик, ОТАЛ, ОТУТ.

NEURO-FUZZY MODELING OF EXPERIMENTAL DATA ON OPTIMIZATION OF THE SPECTRAL CHARACTERISTICS OF FOCL

D.A.Davronbekov¹, Z.T.Khakimov², J.D.Isroilov³

^{1,3}Tashkent University of Information Technologies named after Muhammad al-Khwarizmi
²Center for Higher Education Development Research and Introduction of Advanced Technologies

E-mail: ¹d.davronbekov@gmail.com, ²rmxat@edu.uz

Abstract - In this article, we consider the issues of approximating experimental data. It is shown that the advantage of using fuzzy methods in comparison with other existing methods when choosing an approximation model is efficiency in solving non-formalized or poorly formalized problems, efficiency when working with a large amount of conflicting information, efficiency when working with incomplete information. The approximation of experimental data on the study of spectral lines of FOCL using the regression model, the Sugeno fuzzy knowledge base and the neuro-fuzzy model is carried out.

Key words - approximation, regression model, Sugeno fuzzy knowledge base, neuro-fuzzy model, spectral line, FOCL, FOTS.



НЕЙРО-НЕЧЕТКОЕ МОДЕЛИРОВАНИЕ ЭКСПЕРИМЕНТАЛЬНЫХ ДАННЫХ ПО ОПТИМИЗАЦИИ СПЕКТРАЛЬНЫХ ХАРАКТЕРИСТИК ВОЛС

Д.А.Давронбеков¹, З.Т.Хакимов², Ж.Д.Исроилов³

^{1,3}Ташкентский университет информационных технологий имени Мухаммада аль-Хоразми

²Центр исследований развития высшего образования и внедрения передовых технологий

¹Email: d.davronbekov@gmail.com

²Email: rmxat@edu.uz,

Аннотация—В данной работе рассмотрены вопросы аппроксимации экспериментальных данных. Показано, что преимуществом применения нечетких методов по сравнению с другими существующими методами при выборе модели аппроксимации являются результативность при решении неформализованных или плохо формализованных задач, результативность при работе с большим объемом противоречивой информации, результативность при работе с неполной информацией. Выполнена аппроксимация экспериментальных данных по исследованию спектральных линий ВОЛС с применением регрессионной модели, нечеткой базы знаний Сугено и нейро-нечеткой модели.

Ключевые слова— аппроксимация, регрессионная модель, нечеткая база знаний Сугено, нейро-нечеткая модель, спектральная линия, ВОЛС, ВОСП

I Введение

Разработка математических моделей существующих объектов в естественных условиях имеет большое значение. Сегодня существует несколько методов, технологий и инструментов для определения скрытой, корреляционной, математической закономерности между входными параметрами природного объекта и его выходным состоянием. В большинстве случаев такие задачи формулируются как задачи аппроксимации экспериментальных данных.

Аппроксимация является одним из наиболее важных вопросов, а одним из наиболее сложных вопросов является проблема интеллектуального анали-

за данных. Проблема аппроксимации всегда имеет определенные ошибки в зависимости от используемого инструмента и полноты полученных экспериментальных данных. При решении этой задачи, чем точнее и больше объем данных, полученных на основе вычислительных экспериментов, тем меньше погрешность аппроксимации. Условно аппроксимацию можно разделить на два вида [1 - 4]:

- а) строгая теория математической аппроксимация;
- б) физическая (техническая) аппроксимация.

Строгая теория математической аппроксимации включает в себя следующие методы аппроксимации [4 - 9]:

1. полиномами (многочленами);
2. сплайнами;
3. отрезками ряда Фурье;
4. полиномами по ортогональным многочленами;
5. собственными функциями краевых задач.

Физическая (техническая) аппроксимация включает в себя множество способов аппроксимации и аппроксимирующих функций, выбираемых исходя из конкретно поставленной физической (технической) задачи.

Таким образом, с помощью физической аппроксимации оперативно решается широкий круг задач, актуальных на данный момент времени, связанных с

конкретными проблемами и вопросами прикладного (технического) характера. Строгая теория математической аппроксимации строится как фундаментальная, глобальная теория аппроксимации, которая для решения текущих прикладных практических задач может и не пригодиться.

II Основная часть

Любая задача аппроксимация опирается на сложные математические или эмпирические (интуитивные) методы поиска закономерностей в рассматриваемом временном процессе. Не следует также упускать из вида, что причины этих закономерностей могут изменяться со временем, коренным образом влияя на дальнейшее развитие рассматриваемого процесса. Преимуществом применения нечетких методов по сравнению с другими существующими методами при выборе модели аппроксимации является следующее:

1. Результативность при решении неформализованных или плохо формализованных задач. Из общеизвестных преимуществ нечетких методов самое главное – это отсутствие необходимости в строгой математической спецификации модели, что особенно важно при аппроксимации плохо формализуемых процессов. Известно, что большинство задач аппроксимация экспериментальных данных формализуется.
2. Результативность при работе с большим объемом противоречивой информации. Нечеткие методы наиболее предпочтительны для случаев, когда имеется большой объем анализируемых данных, у которых скрыта закономерность. В данных случаях автоматически выполняется учёт различных нелинейных взаимодействий между оказывающими влияние факторами, что является особенно важным, в частности, для предварительного анализа или отбора начальных данных, нахождения «выпадающих фактов» или грубых ошибок в процессе принятия решений.
3. Результативность при работе с неполной информацией. Является целесообразным использование нечетких методов в задачах с неполной или "за шумленной" информацией, а также в задачах, для которых характерны интуитивные решения.

На основе анализа компонентов волоконно-оптических систем передачи (ВОСП) информации



Рис. 1: Идентификация параметров нечеткой базы знаний

[12-29] установлено, что для идентификации зависимости значений интенсивности спектральных линий от температуры задающего лазера наиболее приемлемыми являются регрессионная модель, нечеткая база знаний Сугено и нейро-нечеткая модель.

Первый метод, многофакторный регрессионный анализ, предназначен для аппроксимация динамики показателей, заданных в виде динамических рядов по выбранному виду регрессии при наличии линейной, степенной или линейно-логарифмической корреляции.

Требуется решить следующие задачи:

- построить уравнение регрессии;
- найти аппроксимационные значения по результативному признаку, задав экспертно-предполагаемые значения по всем признакам-аргументам на горизонте аппроксимация.

Система проводит расчет коэффициента парной корреляции, которая определяется исключительно исходными данными. Парный коэффициент корреляции r_{xy} может иметь знак плюс или минус. Положительная его величина свидетельствует о прямой связи. Чем ближе r_{xy} к единице, тем связь более тесная. Отрицательная величина его свидетельствует об обратной связи; в этом случае границей является -1. Если r_{xy} равен 1, то это свидетельствует о том, что связь между признаками является функциональной, т.е. факторный признак полностью определяет значения результативного. При близости r_{xy} к нулю связь между x и y слабая.

Система автоматически проводит расчет и анализ корреляционной матрицы. Существенные значения парных коэффициентов корреляции свидетельствуют о возможности наличия существенной зависимости между коррелируемыми показателями.

Коэффициенты уравнения множественной линейной регрессии в натуральном масштабе показывают, на какую величину изменится значение результирующего параметра с изменением значений каждого фактора на 1% при фиксированных значениях остальных факторов-аргументов.

Коэффициенты уравнения множественной регрессии в стандартизованном масштабе показывают, на какую часть среднеквадратического отклонения изменится зависимая переменная, если значения каждого из факторов-аргументов изменяются на полную величину своего среднего квадратического отклонения при фиксированных значениях остальных факторов.

Основой оценки существенности взаимосвязей между результирующим признаком и включёнными в состав корреляционной модели факторами-аргументами в конечном счёте могут служить лишь частные коэффициенты детерминации

$$d_i = r_i \cdot b_i$$

представляющие собой произведение парных коэффициентов корреляции r_i на b_i - коэффициенты уравнения множественной регрессии в стандартизованном масштабе.

Частные коэффициенты детерминации характеризуют влияние каждого учтённого фактора в отдельности на уровень результирующего показателя при фиксированных значениях остальных факторов-аргументов.

Полученные оценки результативного параметра могут быть использованы в качестве аппроксимационных.

Второй метод, нечеткая база знаний Сугено, позволяет одновременно настраивать функции принадлежности термов входных переменных и заключения правил с помощью настройке коэффициентов заключений нечетких правил по градиентному методу оптимизации [1, 2]. В начале задачу нечеткой идентификации будем рассматривать как нахождение таких коэффициентов в заключениях правил, которые обеспечивают минимальное отклонения между данными наблюдений и результатами логического вывода по нечеткой базе знаний Сугено [10, 11].

Предполагается, что известны:

1. выборка экспериментальных данных (X_r, y_r) , $r = \overline{1, M}$, где $X_r = (x_{r,1}, x_{r,2}, \dots, x_{r,n})$ - входной вектор в r -ой паре и - соответствующий выход;
2. правила нечеткой базы знаний Такаги-Сугено:

$$\bigcup_{p=1}^{k_j} \left(\bigcap_{i=1}^n x_i = a_{i,jp} \right) \text{ с весом } w_{jp} \rightarrow$$

$$\rightarrow y = b_{j,0} + b_{j,1} \cdot x_1 + b_{j,2} \cdot x_2 + \dots + b_{j,n} \cdot x_n, \quad j = \overline{1, m}.$$

Необходимо найти такие значения коэффициентов заключений правил

$$B = (b_{1,0}, b_{2,0}, \dots, b_{m,0}, b_{1,1}, b_{2,1}, \dots, b_{m,1}, \dots, b_{1,n}, b_{2,n}, \dots, b_{m,n})^T$$

которые обеспечивают минимум квадратичной невязки:

$$\sum_{r=\overline{1, M}} (y_r - y_r^f)^2 \rightarrow \min \quad (1)$$

где y_r^f - результат вывода по нечеткой базе знаний с параметрами B при значении входов из r -й строчки выборки (X_r) .

Входному вектору $X_r = (x_{r,1}, x_{r,2}, \dots, x_{r,n})$ [10, 11]:

$$y_r^f = \frac{\sum_{j=\overline{1, m}} \mu_{d_j}(X_r) \cdot d_j}{\sum_{j=\overline{1, m}} \mu_{d_j}(X_r)} \quad (2)$$

где $d_j \equiv b_{j,0} + \sum_{i=\overline{1, n}} b_{j,i} \cdot x_{r,i}$ - заключение j -го правила;

$\mu_{d_j}(X_r) = \bigvee_{p=\overline{1, k_j}} W_{jp} \cdot \bigvee_{i=\overline{1, n}} [\mu_{jp}(x_{r,i})]$ - степень выполнения заключения j -го правила.

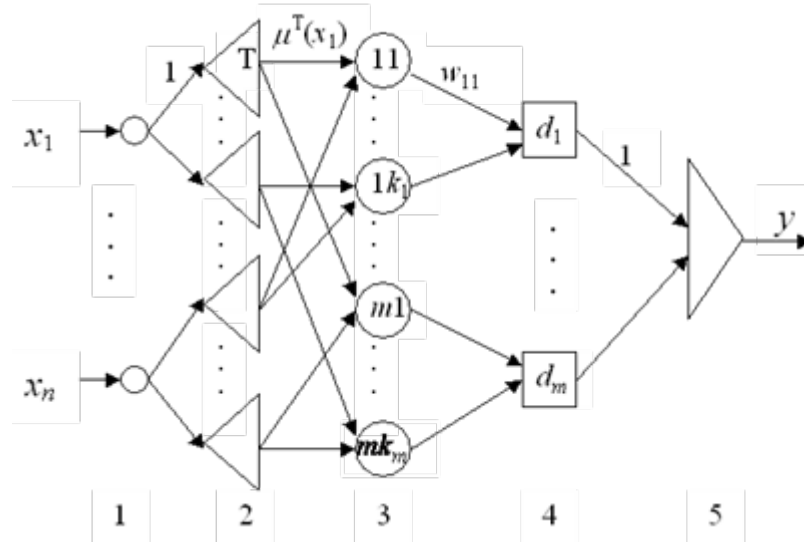


Рис. 2: Структура нейро-нечеткой сети

Узел	Название	Функция
	Вход	$v = u$
	Нечеткий терм	$v = \mu^T(u)$
	Нечеткое правило	$v = \prod_{i=1}^l u_i$
	Класс правил	$v = \sum_{i=1}^l u_i$
	Дефаззификация	$v = \frac{\sum_{j=1}^m u_j \bar{d}_j}{\sum_{j=1}^m u_j}$

Таблица. 1: Элементы нейро-нечеткой сети

Обозначим через $\beta_{j,r} = \frac{\mu_{d_j}(X_r)}{\sum_{k=\overline{1,m}} \mu_{d_k}(X_r)}$ относительную степень выполнения заключения j-го правила для входного вектора X_r . Тогда (2) можно переписать в виде:

$$y_r^f = \sum_{j=\overline{1,m}} \beta_{r,j} \cdot d_j = \sum_{j=\overline{1,m}} (\beta_{r,j} \cdot b_{j,0} + \beta_{r,j} \cdot b_{j,1} \cdot x_{r,1} + \beta_{r,j} \cdot b_{j,2} \cdot x_{r,2} + \dots + \beta_{r,j} \cdot b_{j,n} \cdot x_{r,n})$$

Введем следующие обозначения:

$$Y^f = (y_1^f, y_2^f, \dots, y_M^f)^T;$$

$$Y = (y_1, y_2, \dots, y_M)^T;$$

$$A = \begin{bmatrix} \beta_{1,1} \dots \beta_{1,m} & x_{1,1} \cdot \beta_{1,1} \dots x_{1,1} \cdot \beta_{1,m} & \dots & x_{1,n} \cdot \beta_{1,1} \dots x_{1,n} \cdot \beta_{1,m} \\ \dots & \dots & \dots & \dots \\ \beta_{M,1} \dots \beta_{M,m} & x_{M,1} \cdot \beta_{M,1} \dots x_{M,1} \cdot \beta_{M,m} & \dots & x_{M,n} \cdot \beta_{M,1} \dots x_{M,n} \cdot \beta_{M,m} \end{bmatrix}$$

Тогда задача (1) в матричной форме ставится следующим образом: найти вектор B , чтобы:

$$E = (Y - Y^f)^T \cdot (Y - Y^f) \rightarrow \min \quad (3)$$

где $Y^f = A \cdot B$.

Минимальное значение квадратичной невязки E достигается при $Y^f = Y$, что соответствует решению уравнения

$$Y = A \cdot B \quad (4)$$

Для реальных задач количество настраиваемых параметров меньше объема выборки данных $m \cdot (n + 1) < M$, поэтому уравнение (4) не имеет точного решения. В этом случае решение можно найти, используя псевдоинверсию матрицы A :

$$B = (A^T \cdot A)^{-1} \cdot A^T \cdot Y. \quad (5)$$

Проблемы нахождения решения (5) связаны с возможной сингулярностью матрицы $(A^T \cdot A)$.

Существуют различные алгоритмы нечеткой идентификации, в которых подстройка параметров нечеткой базы знаний Сугено также происходит итерационно по значению "мгновенной ошибки". Ниже рассматривается один такой алгоритм, основанный на градиентном методе оптимизации.

Обозначим "мгновенную ошибку" для r -й строки выборки данных через $E^{(r)} = (y_r - y_r^f)^2 = e^2$. Тогда, согласно градиентному методу, новые значения управляемых переменных рассчитываются по формуле:

$$b_{j,r}^{(r+1)} = b_{j,r}^{(r)} - \alpha \frac{\partial E^{(r)}}{\partial b_{j,i}}, \quad b_{j,i} = b_{j,i}^{(r)}, \quad i = \overline{1,n}, \quad j = \overline{1,m} \quad (6)$$

где $\alpha > 0$ - длина шага, которая задает скорость обучения.

При малых значениях параметра обучение будет медленным. При больших значениях этого параметра возникает опасность переобучения, когда на каждой итерации алгоритма нечеткая модель будет настраиваться только на текущую пару "входы - выход" при этом забывая предыдущий опыт.

Частная производная в (6) имеет простое аналитическое выражение:

$$\frac{\partial E^{(r)}}{\partial b_{j,i}} = 2e\beta_{r,j}x_{r,i}$$

С учетом этого перепишем правило обучения (6) в следующем виде:

$$b_{j,i}^{(r+1)} = b_{j,i}^{(r)} - 2\alpha e\beta_{r,j}x_{r,i}, \quad i = \overline{1,n}, \quad j = \overline{1,m}. \quad (7)$$

Идентификацию параметров нечеткой базы знаний с использованием правила (7) представим следующим алгоритмом (рис.1):

Шаг 1. Установить параметры алгоритма: E^* - допустимая квадратическая невязка и z^* - максимальное количество эпох обучения.

Шаг 2. Рассчитать относительные степени выполнения заключений правил $\beta_{r,j}$ для каждой строки обучающей выборки, $r = \overline{1,M}$, $j = \overline{1,m}$.

Шаг 3. Установить счетчик итераций обучения и счетчик эпох обучения в единицы: $r = 1$ и $z = 1$.

Шаг 4. Установить начальные значения настраиваемых параметров, например, $b_{j,i}^{(r)} = 0$, $i = \overline{1,n}$, $j = \overline{1,m}$.

Шаг 5. Рассчитать значение "мгновенной ошибки" для r -й пары данных из выборки и пересчитать значения настраиваемых параметров по формуле (7).

Шаг 6. Проверить условие " $r < M$ ", если "да" то увеличить счетчик итераций $r = r + 1$ и перейти к шагу 5.

Шаг 7. Рассчитать значение квадратичной невязки на всей выборке данных на z -й эпохе обучения $E^{(z)}$.

Шаг 8. Проверить условие " $E^{(z)} \leq E^*$ ", если "" то перейти к шагу 10.

Шаг 9. Проверить условие " $z < z^*$ ", если "да" то увеличить счетчик эпох $z = z + 1$, установить счетчик итераций обучения в единицу $r = 1$ и перейти к шагу 5.

Шаг 10. Конец.

В приведенном алгоритме используется два критерия останова: первый - по достижению допустимой квадратичной невязки, второй - по превышению заданного количества эпох обучения. На протяжении одной эпохи осуществляется итерационная подстройка параметров по каждой паре "входы - выход" таким образом, шаг 5 алгоритма выполняется ровно M раз. Обучение можно также прекратить, если за одну эпоху настраиваемые параметры практически не изменяются $\max_{j=1, \dots, m, i=1, \dots, n} |b_{j,i}^{<r+1>} - b_{j,i}^{<r>}| < \Delta b^*$ или квадратичная невязка почти не уменьшается

$$E^{(z)} - E^{(z+1)} < \Delta E^*$$

где Δb^* и ΔE^* - малые величины.

До сих пор рассматривалась настройка только заключений правил. Если ввести некоторые ограничения на вид нечеткой базы знаний, тогда применяя идеи метода обратного распространения ошибки, можно получить достаточно простые правила настройки параметров посылок правил. Как это сделать, рассмотрим на примере вывода правил обучения функций принадлежности нечеткой базы знаний Сугено нулевого порядка.

Предположим, что нечеткая база знаний Сугено задана в виде:

$$\bigcap_{i=1}^n x_i = a_{i,j} \rightarrow y = b_j, j = \overline{1, m},$$

что соответствует синглтоной базе знаний. Потребуем, чтобы каждый терм входной переменной использовался только в одном правиле. Чтобы получить дифференцируемые соотношения "входы - выход" будет использоваться гауссовские функции принадлежности:

$$\mu_j(x_i) = \exp\left(-\frac{1}{2} \left(\frac{x_i - c_{i,j}}{\sigma_{i,j}}\right)^2\right)$$

где $\mu_j(x_i)$ - функция принадлежности нечеткого множества $a_{i,j}$;

$c_{i,j}$ и $\sigma_{i,j}$ - параметры функции принадлежности - координата максимума (ядро) и коэффициент концентрации.

Входному вектору $X_r = (x_{r,1}, x_{r,2}, \dots, x_{r,n})$ соответствует такой результат нечеткого вывода:

$$y_r^f = \beta_{r,j} \cdot \sum_{j=1, \dots, m} (b_{j,0} + b_{j,1} \cdot x_{r,1} + b_{j,2} \cdot x_{r,2} + \dots + b_{j,n} \cdot x_{r,n})$$

где $\beta_{r,j}$ - относительная степень выполнения j -го правила для входного вектора X_r .

При использовании в качестве t -нормы умножения относительная степень выполнения j -го правила рассчитывается так:

$$\beta_{r,j} = \frac{\mu_j(x_{r,1}) \cdot \mu_j(x_{r,2}) \cdot \dots \cdot \mu_j(x_{r,n})}{\sum_{k=1, \dots, m} \mu_k(x_{r,1}) \cdot \mu_k(x_{r,2}) \cdot \dots \cdot \mu_k(x_{r,n})} = \frac{\exp\left(-\frac{1}{2} \sum_{i=1, \dots, n} \left(\frac{x_{r,i} - c_{i,j}}{\sigma_{i,j}}\right)^2\right)}{\sum_{k=1, \dots, m} \left(-\frac{1}{2} \sum_{i=1, \dots, n} \left(\frac{x_{r,i} - c_{i,k}}{\sigma_{i,k}}\right)^2\right)}$$

Настраиваемыми параметрами при идентификации будут коэффициенты в заключениях правил s и параметры функций принадлежности нечетких термов: координаты максимумов $C = (c_{1,1}, c_{2,1}, \dots, c_{n,1}, c_{2,1}, c_{2,2}, \dots, c_{n,2}, \dots, c_{1,m}, c_{2,m}, \dots, c_{n,m})$ и коэффициенты концентраций

$$S = (\sigma_{1,1}, \sigma_{2,1}, \dots, \sigma_{n,1}, \sigma_{2,1}, \sigma_{2,2}, \dots, \sigma_{n,2}, \dots, \sigma_{1,m}, \sigma_{2,m}, \dots, \sigma_{n,m}).$$

Задача идентификации состоит в нахождении вектора (B, C, S) , обеспечивающего выполнение (3).

Находя частные производные "мгновенной ошибки" $E^{<r>} = (y_r - y_r^f)^2 = e^2$ по управляемым переменным $b_j, c_{i,j}$, и $\sigma_{i,j}$, получаем следующие правила обучения:

$$b_j^{<r+1>} = b_j^{<r>} - \alpha \frac{\partial E^{<r>}}{\partial b_j} = b_j^{<r>} - 2\alpha e \beta_{r,j} \quad (8)$$

$$c_{i,j}^{<r+1>} = c_{i,j}^{<r>} - \alpha \frac{\partial E^{<r>}}{\partial c_{i,j}} - \alpha e \beta_{r,j} (b_j^{<r>} - y_r) \frac{x_{r,i} - c_{i,j}^{<r>}}{(\sigma_{i,j}^{<r>})^2} \quad (9)$$

Режим работы стенда	Длина волны	Значение интенсивности спектральных линий (в относительных единицах) при различных температурах задающего лазера							Среднее значение
		10°C	15°C	20°C	25°C	30°C	35°C	40°C	
АОПФ–выкл., УБВ–выкл.; 1 спектр. пик	λ_1	22	19	17	16	15	13	9	15,86
АОПФ–выкл., УБВ–выкл.; 2 спектр. пик	λ_2	15	14	13	12	11	9	7	11,57
АОПФ–выкл., УБВ–выкл.; 3 спектр. пик	λ_3	7	6	5	5	4	4	3	14,86
АОПФ – выкл., УБВ–вкл.; 1 спектр. пик	λ_1	90	84	77	71	64	58	51	70,71
АОПФ–выкл., УБВ–вкл.; 2 спектр. пик	λ_2	116	107	99	92	83	75	67	91,29
АОПФ–выкл., УБВ–вкл.; 3 спектр. пик	λ_3	74	68	62	57	51	45	39	56,57
АОПФ–вкл., УБВ–вкл.; опт. настройка АОПФ, 1 спектр. пик	λ_1	119	109	100	93	86	79	73	94,14
АОПФ–вкл., УБВ–вкл.; опт. настройка АОПФ, 2 спектр. пик	λ_2	110	100	91	86	81	75	69	87,43
АОПФ–вкл., УБВ–вкл.; опт. настройка АОПФ, 3 спектр. пик	λ_3	113	104	95	90	84	78	72	90,86

Таблица. 2: Зависимость значений интенсивности спектральных линий от температуры задающего лазера

Режим работы стенда	Длина волны	Значение интенсивности спектральных линий (в относительных единицах)							Среднее значение
		1	2	3	4	5	6	7	
АОПФ–выкл., УБВ–выкл.; 1 спектр. пик	λ_1	17	19	17	16	18	17	16	17,14
АОПФ–выкл., УБВ–выкл.; 2 спектр. пик	λ_2	13	12	12	14	13	13	14	13
АОПФ–выкл., УБВ–выкл.; 3 спектр. пик	λ_3	5	5	4	6	6	5	4	5
АОПФ–выкл., УБВ–вкл.; 1 спектр. пик	λ_1	77	80	76	77	81	77	76	77,71
АОПФ–выкл., УБВ–вкл.; 2 спектр. пик	λ_2	99	97	97	96	100	97	99	97,86
АОПФ–выкл., УБВ–вкл.; 3 спектр. пик	λ_3	62	61	62	60	62	62	64	61,86
АОПФ–вкл., УБВ–вкл., опт. настройка АОПФ; 1 спектр. пик	λ_1	100	98	98	100	98	97	100	98,71
АОПФ–вкл., УБВ–вкл., опт. настройка АОПФ; 2 спектр. пик	λ_2	91	88	89	91	92	91	92	90,57
АОПФ–вкл., УБВ–вкл., опт. настройка АОПФ; 3 спектр. пик	λ_3	95	93	92	94	96	95	97	94,57
АОПФ–выкл., УБВ–вкл.; 2 спектр. пик	λ_2	116	107	99	92	83	75	67	91,29
АОПФ–выкл., УБВ–вкл.; 3 спектр. пик	λ_3	74	68	62	57	51	45	39	56,57
АОПФ–вкл., УБВ–вкл.; опт. настройка АОПФ, 1 спектр. пик	λ_1	119	109	100	93	86	79	73	94,14
АОПФ–вкл., УБВ–вкл.; опт. настройка АОПФ, 2 спектр. пик	λ_2	110	100	91	86	81	75	69	87,43
АОПФ–вкл., УБВ–вкл.; опт. настройка АОПФ, 3 спектр. пик	λ_3	113	104	95	90	84	78	72	90,86

Таблица. 3: Зависимость значений интенсивности спектральных линий от режима работы стенда




Рис. 3: Зависимость значений интенсивности спектральных линий от режима работы станда




Рис. 4: Зависимость значений интенсивности спектральных линий от режима работы станда

$$c_{i,j}^{<r+1>} = c_{i,j}^{<r>} - \alpha \frac{\partial E^{<r>}}{\partial c_{i,j}} = \alpha e \beta_{r,j} (b_j^{<r>} - y_r) \frac{x_{r,i} - c_{i,j}^{<r>}}{(\sigma_{i,j}^{<r>})^2} \quad (10)$$

$$\sigma_{i,j}^{<r+1>} = \sigma_{i,j}^{<r>} - \alpha \frac{\partial E^{<r>}}{\partial \sigma_{i,j}} = \sigma_{i,j}^{<r>} - \alpha e \beta_{r,j} (b_j^{<r>} - y_r) \frac{(x_{r,i} - c_{i,j}^{<r>})^2}{(\sigma_{i,j}^{<r>})^3} \quad (11)$$

где $i = \overline{1, n}$; $j = \overline{1, m}$; $r = \overline{1, M}$.

Для каждой пары данных "входы - выход" обучение происходит в два этапа. На первом этапе осуществляется нечеткий логический вывод для текущего входного вектора. На втором этапе вычисляется "мгновенная ошибка разницы между полученным и ожидаемым значениями выхода, и модифицируются параметры нечеткой базы знаний. При представлении нечеткой модели в виде нейро-нечеткой сети первый этап обучения можно сопоставить с прямым распространением сигнала по сети, а второй этап - с обратным распространением ошибки.

В правила обучения (8), (9) и (10) входят одни и те же множители, что позволяет быстро пересчитывать

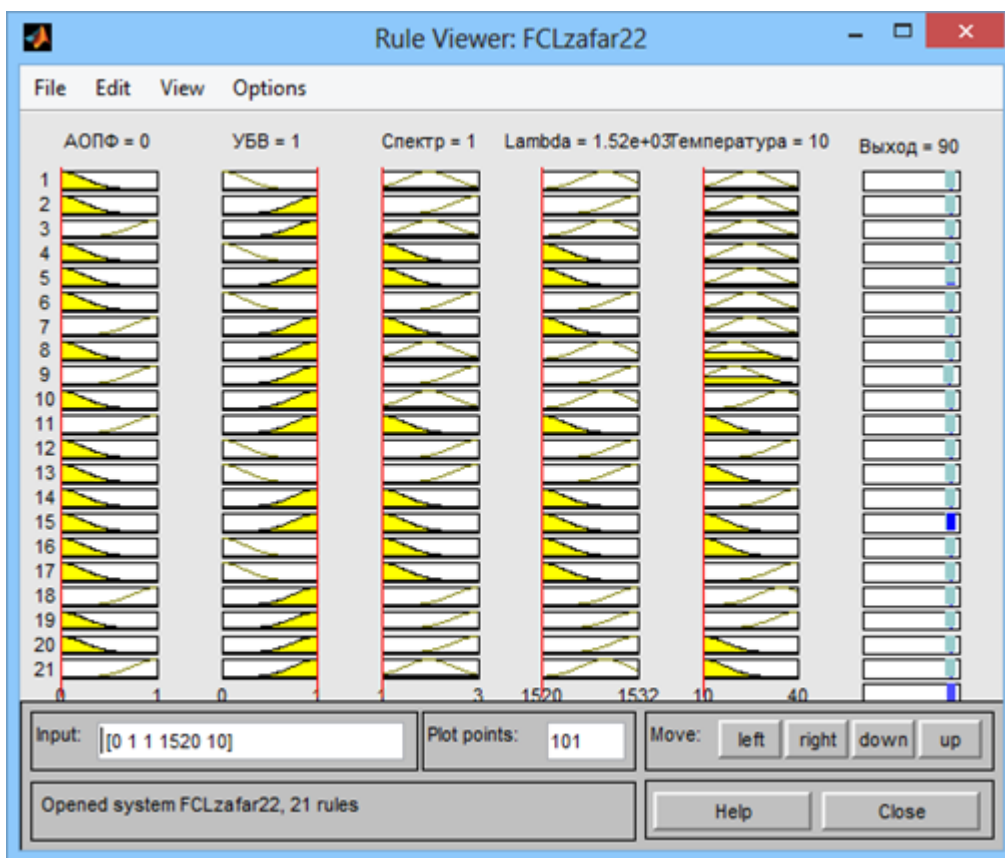


Рис. 5: Генерация нечетких баз знаний и обучающих выборок




Рис. 6: Моделирование зависимости значений интенсивности спектральных линий от температуры задающего лазера

значения настраиваемых параметров. При использовании других типов функций принадлежности правила их обучения получаются не такими быстрыми. Обучение функций принадлежности по формулам (8) - (10) по сравнению с настройкой заключений пра-

вил по формуле (7) является более трудоемкой вычислительной процедурой в связи с необходимостью пересчета относительных степеней выполнения правил после каждой итерации алгоритма обучения.

В третьем методе, нейро-нечеткая модель, до на-




Рис. 7: Погрешности аппроксимации моделирования зависимости значений интенсивности спектральных линий от температуры задающего лазера



	NCluster	ANFIS	Regres-L	Regres-KV
Средняя погрешность	0,007586	0,128391	7,472874	7,372414

Рис. 8: Погрешности аппроксимации моделирования зависимости значений интенсивности спектральных линий от температуры задающего лазера

чала обучения нейросетевая модель допускает введение произвольных параметров, указанных экспертом (функциональных факторов процесса). Каждый

из этих параметров будет учтен при выполнении аппроксимации с тем "весом который позволит получить от такого фактора наиболее точный результат.



	NCluster	ANFIS	Regres-L	Regres-KV
Средняя погрешность	0,03093	0,29686	6,137093	6,125233

Рис. 9: Погрешности аппроксимации моделирования зависимости значений интенсивности спектральных линий от режима работы станда

Рассматривается объект вида

$$y = f(x_1, x_2, \dots, x_n)$$

для которого связь <входы $(x_i) - (y)$ > .

Здесь предлагается способ представления лингвистической информации об объекте (11) в виде специальной нейро-нечеткой сети, изоморфной базе знаний. Структура такой сети представлена на рис.2, а содержание узлов показано в таблице 1. Из рис.2 видно, что нейро-нечеткая сеть имеет пять слоев:

слой 1 - входы объекта идентификации;

слой 2 - нечеткие термы, используемые в базе знаний;

слой 3 - строки-конъюнкции нечеткой базы знаний;

слой 4 - правила, объединяемые в классы $d_j, j = \overline{1, m}$;

слой 5 - операция дефаззификации, т.е. преобразование результатов нечеткого логического вывода в четкое число.

Число узлов в нейро-нечеткой сети определяется так:

слой 1 - по количеству входов объекта идентификации;

слой 2 - по количеству нечетких термов в базе знаний;

слой 3 - по количеству строк-конъюнкций в базе знаний;

слой 4 - по количеству классов, на которые разбивается диапазон выходной переменной.

Дуги графа взвешиваются следующим образом:

- единицей - дуги между 1-м и 2-м слоями;
- функциями принадлежности входа к нечеткому терму - дуги между 2-м и 3-м слоями;
- весами правил - дуги между 3-м и 4-м слоями;
- единицей - дуги между 4-м и 5-м слоями.

В таблице 1 обозначено: $\mu^T(u)$ - функция принадлежности переменной u к терму T ; d_j - центр класса

$d_j \in [\underline{y}, \bar{y}]$. При определении элементов «нечеткое правило» и «класс правил» нечетко-логические операции «min» и «max» заменены арифметическими операциями умножения и сложения. Здесь это позволяет получить аналитические выражения, удобные для дифференцирования.

Суть обучения состоит в подборе таких весов дуг, которые минимизируют различие между результатами нейро-нечеткой аппроксимации и реальным поведением объекта. Для обучения используется система рекуррентных соотношений:

$$w_{jp}(t+1) = w_{jp}(t) - \mu \frac{\partial E_t}{\partial w_{jp}(t)} \quad (12)$$

$$c_i^{jp}(t+1) = c_i^{jp}(t) - \eta \frac{\partial E_t}{\partial c_i^{jp}(t)} \quad (13)$$

$$b_i^{jp}(t+1) = b_i^{jp}(t) - \eta \frac{\partial E_t}{\partial b_i^{jp}(t)}, j = \overline{1, m}, i = \overline{1, n}, p = k_j. \quad (14)$$

минимизирующий критерий

$$E_t = \frac{1}{2} (\hat{y}_t - y_t)^2 \quad (15)$$

применяемый в теории нейронных сетей, где \hat{y}_t и y_t - теоретический и экспериментальный выходы объекта (11) на t -м шаге обучения; $w_j^p, c_i^{jp}, b_i^{jp}$ - веса правил (w) и параметры функций принадлежности (b, c) на t -м шаге обучения; η - параметр обучения, который может выбираться в соответствии с рекомендациями работы.

Частные производные, входящие в соотношения (12)-(14), характеризуют чувствительность ошибки (E_t) к изменению параметров нейро-нечеткой сети, и вычисляются следующим образом:

$$\frac{\partial E_t}{\partial w_{jp}} = \varepsilon_1 \varepsilon_2 \varepsilon_3 \frac{\partial \mu^{dj}(y)}{\partial w_{jp}} \quad (16)$$

$$\frac{\partial E_t}{\partial c_i^{jp}} = \varepsilon_1 \varepsilon_2 \varepsilon_3 \varepsilon_4 \frac{\partial \mu^{jp}(x_i)}{\partial c_i^{jp}} \quad (17)$$

$$\frac{\partial E_t}{\partial b_i^{jp}} = \varepsilon_1 \varepsilon_2 \varepsilon_3 \varepsilon_4 \frac{\partial \mu^{jp}(x_i)}{\partial b_i^{jp}} \quad (18)$$

где

$$\varepsilon_1 = \frac{\partial E_t}{\partial y} = y_t - \hat{y}_t \quad (19)$$

$$\varepsilon_2 = \frac{\partial y}{\partial \mu^{dj}(y)} = \frac{\bar{d}_j \sum_{j=1}^m \mu^{dj}(y) - \sum_{j=1}^m \bar{d}_j \mu^{dj}(y)}{\left(\sum_{j=1}^m \mu^{dj}(y) \right)^2} \quad (20)$$

$$\varepsilon_3 = \frac{\partial \mu^{dj}(y)}{\partial \left(\prod_{i=1}^n \mu^{jp}(x_i) \right)} = w_{jp} \quad (21)$$

$$\varepsilon_4 = \frac{\partial \left(\prod_{i=1}^n \mu^{jp}(x_i) \right)}{\partial v^{jp}(x_i)} = \frac{1}{\mu^{jp}(x_i)} \prod_{i=1}^n \mu^{jp}(x_i) \quad (22)$$

$$\frac{\partial \mu^{dj}(y)}{\partial w_{jp}} = \prod_{i=1}^n \mu^{jp}(x_i) \quad (23)$$

$$\frac{\partial \mu^{jp}(x_i)}{\partial c_i^{jp}} = \frac{2c_i^{jp}(x_i - b_i^{jp})^2}{((c_i^{jp})^2 + (x_i - b_i^{jp})^2)^2} \quad (24)$$

$$\frac{\partial \mu^{jp}(x_i)}{\partial b_i^{jp}} = \frac{2(c_i^{jp})^2(x_i - b_{jp})}{((c_i^{jp})^2 + (x_i - b_i^{jp})^2)^2} \quad (25)$$

Аналогично правилу, алгоритм обучения нейро-нечеткой сети состоит из двух фаз. На первой фазе вычисляется модельное значение выхода объекта (y), соответствующее заданной архитектуре сети. На второй фазе вычисляется значение невязки (E_t) (16) – (25).

На основании проведенного исследования выполнены вычислительные эксперименты по определению зависимости интенсивности спектральной линии от температуры лазера и зависимости интенсивности спектральной линии от режима работы. В первом случае основными входными параметрами были определены АОПФ-0, 1, УБВ-0, 1, спектр-1, 2, 3, λ - [1520, 1533] и температура- [10, 40] (таблица 2).

Во втором случае были определены АОПФ-0, 1, УБВ-0, 1, спектр-1, 2, 3, λ - [1520, 1533] и единицы - [1, 7] (таблица 3).

Для генерации нечетких баз знаний и обучающих выборок использовалась эталонная модель "пять входов - один выход" (рис.4). В качестве входов были приняты следующие параметры: режим работы АОПФ, режим работы УБВ, значение спектрального пика, длина волны, температура. Выходным параметром является значение интенсивности спектральной линии.

Результаты моделирования зависимости значений интенсивности спектральных линий от температуры задающего лазера приведены на рис.5, а моделирования зависимости значений интенсивности спектральных линий от режима работы стэнда приведены на рис.6.

На рис.5 и рис.6 принято обозначение «ФАКТ» – фактические значения выборок. Моделирование проводилось с помощью аппроксимации по трем методам идентификации нелинейной зависимости - с помощью регрессионной модели (график Regres-L, Regres-KV), нечеткой базы знаний Сугено (график Cluster) и нейро-нечеткой модели (график ANFIS) (рис.5 и рис.6). В процессе проведения вычислительных экспериментов определены погрешности аппроксимации при моделировании зависимости значений интенсивности спектральных линий от температуры задающего лазера (рис.7) и при моделировании зависимости значений интенсивности спектральных линий от режима работы стэнда (рис.8).

III ЗАКЛЮЧЕНИЕ

В результате проведенного исследования предложен метод нейро-нечёткого моделирования экспериментальных данных по оптимизации спектральных характеристик ВОЛС, основанный на построении аппроксимирующих моделей по выборкам реальных данных. На основании предложенного метода создана аппроксимирующая модель экспериментальных данных по оптимизации спектральных характеристик ВОЛС по трем методам идентификации нелинейной зависимости - с помощью регрессионной модели, нечеткой базы знаний Сугено и нейро-нечеткой модели. Ошибка прогноза по первой модели составила – 0-7,47%, по второй модели 0-0,03%, а по третьей модели 0-0,3%.

Список литературы

- [1] Takagi T., Sugeno M. Fuzzy Identification of Systems and Its Applications to Modeling and Control // IEEE Trans. on Systems, Man, and Cybernetics. – 1985, Vol. 15. - № 1. - p. 116 - 132.
- [2] Yager R., Filev D. Essentials of Fuzzy Modeling and Control. USA: John Wiley Sons. - 1994. – 387 p.
- [3] Математика: Энциклопедия / под ред. Ю.В. Прохорова. - М.: Большая Российская энциклопедия, 2003.
- [4] Juk V. V. Leksii po teorii approksimatsii. - SPb.: - izd-vo VVM.- 2008. - 396 s.
- [5] Daugavet I.K. Teoriya priblijennix metodov. Lineynie uravneniya: uchebnoe posobie. - 2-e izd. - SPb.: BVX-Peterburg. - 2006. - 278 s.
- [6] A. P. Kolesnikov. Teoriya priblijeniy. Funkcional'nie splayni v topologicheskix vektornix prostranstvax. - M.: - Librokom. - 2013. - 462 s.
- [7] Muxamedieva D.T., Minglikulov Z.B. Obuchenie neyro-nechetkoy seti pri raznix funktsiyax prinadlezhnosti // Ximicheskaya texnologiya. Kontrol' i upravlenie. - 2013. - №2. – s. 68-75.
- [8] Minglikulov Z.B. O nelineynoy modeli klassifikatsii sostoyaniy slaboformalizuemix prosessov s ispol'zovaniem nechetkix pravil vivoda // Ximicheskaya texnologiya. Kontrol' i upravlenie. - 2013. - №3. - s.82-85.
- [9] Minglikulov Z.B. Algoritm resheniya zadachi nechyotkoy klasterizatsii // Problemi informatiki - 2014. -№1.- s.10-14.
- [10] Kamilov M.M., Minglikulov Z.B. Algoritm resheniya zadachi nechyotkoy klasterizatsii, osnovaniy na uchyote nechyotkix otnosheniy mejdya ob'ektami // Dokladi Akademii nauk Respubliki Uzbekistan. - 2014. - №4. - s.18-21.
- [11] Minglikulov Z.B. Algoritmi prinyatiya diagnosticheskix resheniy s ispol'zovaniem neyronchetkix texnologiy // Problemi informatiki i energetiki. - Toshkent. - 2011. - №1. - s. 71-76.
- [12] Hakimov Z.T., Davronbekov D.A. Equalization of spectral characterist of optical signals by acousto-optic filters // 2007 3rd IEEE/IFIP International Conference in Central Asia on Internet, ICI 2007.
- [13] Matyokubov U.K., Davronbekov D.A. The Impact of Mobile Communication Power Supply Systems on Communication Reliability and Viability and Their Solutions // International Journal of Advanced Science and Technology. -2020, Vol. 29- № 5. - p. 3374 - 3385.
- [14] Davronbekov D.A., U.T.Aliev, J.D.Isroilov, X.F.Alimdjanov. Power Providing Methods for Wireless Sensors // 2019 International Conference on Information Science and Communications Technologies. Applications, Trends and Opportunities, ICISCT 2019. - p.1-3.
- [15] D.Davronbekov, U.T.Aliev, J.D.Isroilov. Using the energy of electromagnetic radiation as a source of power // 2017 International Conference on Information Science and Communications Technologies, ICISCT 2017.

- [16] U.K.Matyokubov, D.A.Davronbekov. Increasing Energy Efficiency of Base Stations in Mobile Communication Systems // Acta of Turin Polytechnic University in Tashkent. - 1/2020. - p.22-27.
- [17] D.A.Davronbekov, U.K.Matyokubov. The Role of Network Components in Improving the Reliability and Survivability of Mobile Communication Networks // Acta of Turin Polytechnic University in Tashkent. - 2020, Vol.10: Iss.3, Article 2. - p.7-14.
- [18] Davronbekov D.A., Xakimov Z.T. Osobennosti ekspluatatsii volokonno-opticheskogo kabelya pri izmeneniyax temperaturi // Scientific Collection «InterConf». Proceedings of the 1st International Scientific and Practical Conference «Recent Scientific Investigation». - 2020. -№1(37) - s. 996-1001.
- [19] T.D.Radjabov, B.N.Rakhimov, D.A.Davronbekov. Optoelectronic devices for automatic diagnosis of the physical properties of mechanical disturbances, damage dams // Sevenths World Conference on Intelligent Systems for Industrial Automation, WCIS-2012, Vol.II. - p.246-248.
- [20] Nazarov A.M., Rakhmonov A.R., Khurbanbayev Sh.Z., Mavlyanov A.Sh., Davronbekov D.A. The device for diagnostics of optical fiber cables // European Journal of Technical and Natural Sciences Scientific journal. - 2017. - №5. - p.82-88.
- [21] D.A.Davronbekov, Z.T.Xakimov. Metodi uluchsheniya spektral'nix karakteristik volokonno-opticheskix sistem peredachi informatsii. Monografiya - T.: «Yoshlar nashriyoti uyi». - 2020 - 112 s.
- [22] Davronbekov D., Khakimov Z., Isroilov J. Features Identifiers Implemented in the Context of Generations of Mobile Cellular Development // International Journal of Advanced Trends in Computer Science and Engineering. -2020, Volume 9. - №5 - p.8753-8757.
- [23] Patent na izobretenie № IAP 04465 / Radjabov T.D., Nazarov A.M., Davronbekov D.A., Simonov A.A., Xakimov Z.T., Pichko S.V. Ustroystvo dlya diagnostiki i optimizatsii spektral'nix karakteristik optovolokonnix sistem peredachi informatsii // Rasmiy axborotnoma. - 2012. - №1(129).
- [24] D.A.Davronbekov, A.M.Nazarov. One of the Ways to Diagnose Elements of Fiber Optic Systems of Mobile Communications // International scientific journal “Science and World”. - 2019, Vol. I. - № 6 (70) - p.18-25.
- [25] Radjabov T.D., Khakimov Z.T., Davronbekov D.A. Development of the stand for researches spectral characteristics of the optical fibre // ICEIC 2008 The 9th International Conference on Electronics, Information and Communication. - 2008. - p.410-411.
- [26] Radjabov T.D., Davronbekov D.A., Xakimov Z.T. Issledovanie spektral'nix karakteristik opticheskix signalov VOSP s ispol'zovaniem AOPF // Infokommunikatsii: Seti- Texnologii-Resheniya». - 2008. - №1, - s.3-7.
- [27] Davronbekov D.A., Jumamuratov I.K. Osobennosti primeniya VOLS v sistemax mobil'noy svyazi // Scientific Collection «InterConf». Proceedings of the 1st International Scientific and Practical Conference «Experimental and Theoretical Research in Modern Science». - 2020. -№2(35).- s.627-632.
- [28] Davronbekov D.A., Xakimov Z.T., Isroilov J.D. Opredelenie granisi texnologicheskogo zapasa opticheskogo volokna s pryamolineynimi elementami // Scientific Collection «InterConf». Proceedings of the 1st International Scientific and Practical Conference «Science, Education, Innovation: Topical Issues and Modern Aspects». - 2020. -№2(38) - s.1163-1169.
- [29] Davronbekov D.A., Khakimov Z.T. Technique Design of Filter on Surface-acoustic Waves // Acta of Turin Polytechnic University in Tashkent. -2020. - №10. - p.18-25.