

ПОСТРОЕНИЕ СОСТАВНОГО НЕЙРОСЕТЕВОГО КЛАССИФИКАТОРА ДЛЯ ВЫБОРА ЭФФЕКТИВНОГО МЕТОДА ОЦЕНИВАНИЯ ПАРАМЕТРОВ МОДЕЛЕЙ В КЛАССЕ МЕТОДОВ СМЕЩЕННОГО И РОБАСТНОГО ОЦЕНИВАНИЯ

Как правило, для выбора оптимального метода решения задачи в АСУ необходимо участие как специалистов в предметной области решаемой задачи, так и участие специалиста в области методов ее решения. Это связано с тем, что специалист в предметной области не имеет достаточного уровня подготовки в области математических, статистических и др. методов решения задач. Поэтому необходимо иметь средства, которые позволят на инженерном уровне осуществлять выбор наиболее эффективного метода для синтеза модели функциональной задачи АСУ и непосредственно ее решение.

В различных литературных источниках [1] приведено множество критериев, позволяющих сделать выбор лучшей модели на основании подбора наименьшего числа коэффициентов модели, совместимого с допустимой ошибкой, разумного физического обоснования, минимальной суммы квадратов отклонений между предсказанными и эмпирическими значениями, минимальной дисперсии зависимой переменной.

Существующие подходы к выбору наиболее эффективного метода оценивания параметров модели базируются на построении математических моделей зависимости эффективности указанных методов от характеристик исходной информации процесса [2, 3], анализе обобщенных критериев, основанных на мере рассеивания и индексе ошибки относительных среднеквадратичных критериев [1] и др. Указанные подходы имеют ряд существенных недостатков, в частности отсутствует четкий алгоритм выбора класса методов оценивания, существует противоречивость результатов, получаемых различными методами, возникает пересечение областей применимости исследуемых методов оценивания, а самое основное – ориентация на профессионализм эксперта, что значительно сужает область применения этих методов.

Поэтому актуальной является задача построения модели, устанавливающей зависимость статистических характеристик объекта исследования и выбором эффективного класса методов оценивания параметров математических моделей, что, по сути, представляет собой задачу классификации.

В силу указанных недостатков существующих подходов поставленную задачу предлагается решать на основе введения в блок математического обеспечения АСУ нейросетевого классификатора, что позволит выявить зависимость между внутренней структурой входной информации исследуемого объекта и эффективностью методов оценивания. Под нейросетевым классификатором будем подразумевать формализованную процедуру, позволяющую осуществить на первом этапе переход от внутренней структуры исходной информации к классам методов оценивания, на втором – выбор подкласса внутри класса методов, на третьем – выбор эффективного метода внутри подкласса, полученного на предыдущем этапе.

Методика построения составного нейросетевого классификатора заключается в следующем:

1. Предварительная обработка исходных данных процесса.
2. Промежуточная обработка данных.
3. Конструирование, обучение и оценка качества нейронной сети.
4. Оценка качества классификатора и тестирование.

Рассмотрим применение этой методики для построения составного нейросетевого классификатора по выбору эффективного метода оценивания параметров математической модели квазистационарного статического процесса, выборочные значения которого подвержены эффекту мультиколлинеарности и зашумленности.

На сегодняшний день не существует формальной процедуры, позволяющей однозначно выбрать класс методов оценивания параметров математической модели объекта исследования в случае одновременного присутствия мультиколлинеарности и высокой "загрязненности" исходной информации.

Опишем модельный эксперимент подготовки и предварительной обработки исходных данных процесса.

Проведенный анализ [1, 2, 3, 4] и исследования позволили выявить следующие параметры, существенно влияющие на показатель эффективности. Для методов смещенного оценивания (МСО): уровень мультиколлинеарности, величина дисперсии помех, количество независимых переменных, величина максимального коэффициента корреляции, показатель обусловленности матрицы входных переменных, норма матрицы, длина выборок; для методов робастного оценивания (МРО) – степень загро-

нения независимых переменных, качественный параметр, определяющий форму выбросов в независимых переменных, соотношение масштабов "засоряющего" и основного распределений "загрязненного" распределения ошибок модели, длина хвоста "загрязненного" распределения независимых переменных или величина выбросов в случае остаточных выбросов, которые и были использованы в качестве доминирующих параметров при формализации подхода к выбору класса методов оценивания.

Для генерации выборочных характеристик исходной информации процессов, имеющих линейную зависимость входных векторов и различную форму выбросов, предлагается следующий алгоритм:

- 1) задание длины выборок и числа независимых переменных исследуемого процесса n и p ;
- 2) формирование выборочных значений независимых переменных x . В случае независимой переменной без выбросов, выборка генерируется как стандартная нормальная выборка вида $N(0, 1)$. Для генерации выбросов в независимой переменной в виде длинного хвоста используется модель плотности распределения

$$F(x)_{h=1} = (1 - \gamma)N(0,1) + \sum_{j=1}^{\max \text{int}\{ny\}} \frac{\gamma}{\max \text{int}\left\{\left(\frac{\min\{ny, j\}}{ny}\right)^d\right\}}, \quad (1)$$

где γ – степень засоренности выборки независимой переменной; n – длина выборки; d – длина хвоста загрязненного распределения; $l(\cdot)$ – детерминированный скаляр со значением (\cdot) ; $\max \text{int}\{\cdot\}$ – ближайшее целое число, большее чем $\{\cdot\}$.

Для генерации остаточных выбросов в независимой переменной воспользуемся упрощенной моделью плотности распределения в виде:

$$F(x)_{h=0} = (1 - \gamma)N(0,1) + \gamma 1_d. \quad (2)$$

Если необходимо генерировать "точки плохого высокого влияния" [3], то выборку значений зависимой переменной необходимо формировать на основании независимых переменных без загрязнения, а только затем подвергать независимые переменные процедуре наложения выбросов в соответствии с (2). Если же необходимо имитировать "точки хорошего высокого влияния", то значения выборки зависимой переменной необходимо формировать по засоренным независимым переменным, сгенерированным согласно (1).

Чтобы получить значения независимых переменных с заданными корреляционными зависимостями с помощью алгоритма, описанного в [2], сначала задаем: количество независимых переменных p , в соответствии с длиной p задаем значения собственных векторов q_{ij} , затем по алгоритму, описанному в [2], генерируем единственную корреляционную матрицу $X'X$, соответствующую заданным значениям собственных векторов q_{ij} . Задаем длину выборки n и по корреляционной матрице получаем значения независимых переменных с заданной степенью мультиколлинеарности. Рассчитываются элементы этих матриц для следующих значений коэффициентов корреляции $\rho=0.80; 0.90; 0.95; 0.99$, которые соответствуют степени мультиколлинеарности $\alpha=5, 8, 10, 100$;

3) генерация выборки значений остатков или ошибок регрессионной модели e_i . При построении регрессионных зависимостей закон распределения ошибок модели зависит от наличия выбросов в исходных данных. Поэтому необходимо моделировать выборки с различной структурой и степенью "засоренности". В этой ситуации, генерируя исходные выборки данных в соответствии с вышеуказанными влияющими параметрами, нельзя получить плавное изменение свойств закона распределения ошибок регрессионной модели [3, 6], так как различные виды выбросов в исходных данных могут порождать одинаковые законы распределения ошибок регрессионной модели. В этой связи целесообразно перейти от генерации прямых параметров исходных данных – выборок зависимой и независимых переменных к генерации косвенной – закона распределения ошибок регрессионной модели по заданной плотности распределения вероятностей

$$F(e) = (1 - \lambda)N(0,1) + \lambda N(0, \sigma), \quad (3)$$

где λ – степень загрязнения распределения; $N(0,1)$ – стандартный нормальный закон распределения; $\sigma = (\sigma_y / \sigma_o) \geq 1$ – отношение масштабов загрязняющего и основного распределений;

4) задание структуры модели и получение значений зависимой переменной y_i . Задаем структуру математической модели: линейная по параметрам $y_i = \beta_0 + \sum_{j=1}^p \beta_j x_{ji} + e_i$, $i = \overline{1, n}$; $j = \overline{1, p}$. Зависи-

мые и независимые переменные предварительно нормируются. В соответствии со структурой модели и количеством независимых переменных задаем истинные значения вектора коэффициентов модели β , которые генерировались случайным образом в нормализованной форме в диапазоне $(\beta_{\max}, \beta_{\min})$;

5) расчет значений вектора зависимой переменной y , по заданным истинным значениям коэффициентов, структуре модели и вектору ошибок e_i . Проверка основных статистических гипотез для значений зависимой переменной y_i : стационарность, стохастичность и др.

На основании характеристик, задаваемых при генерации исходной информации, формируем вектор входных признаков, позволяющий провести распознавание классов МСО, МРО и МНК. Укажем составляющие этого входного вектора и диапазоны варьирования значений его параметров: f_1 – объем выборки ($n=20\div 200$), f_2 – количество независимых переменных ($p=2\div 7$), f_3 – показатель степени мультиколлинеарности ($\alpha=1\div 100$), f_4 – дисперсия ошибки зависимой переменной ($\sigma^2=0,01\div 0,5$), f_5 – степень засоренности смешанного закона распределения ошибок модели регрессии ($\lambda=0\div 0,3$), f_6 – степень загрязнения независимых переменных ($\gamma=0\div 0,1$), f_7 – качественный параметр, определяющий форму выбросов в независимых переменных ($h=0; 1$).

Экспериментальные исследования по выбору топологии и оптимальной архитектуры нейронной сети для распознавания классов МСО, МРО и МНК, проведенные на основании обучающей выборки f_{1i}, \dots, f_{7i} , $i = \overline{1, m}$, где m – объем выборки, описаны в [5]. Для решения этой задачи выбрана вероятностная нейронная сеть, позволившая получить минимальные значения совокупности критериев оценки качества обучения сети: коэффициента уверенности, средней относительной и суммарной квадратической ошибки.

Подведем итоги результатов проведенного эксперимента по сравнению эффективности классов МСО, МРО и МНК. Как уже было отмечено, достаточно сложно на основании характеристик входной информации провести разграничение рассматриваемых классов методов в связи с пересечением областей их эффективности. Поэтому диапазоны варьирования параметров f_1, \dots, f_7 имеют размытый характер и не имеют четких границ. Однако, в результате проведенного исследования было выявлено, что оценки коэффициентов модели наиболее точно рассчитываются на основе МСО при таких диапазонах варьирования значений параметров: $n=[70\div 200]$, $p=[3\div 7]$, $\alpha=[5\div 100]$, $\sigma^2=[0,01\div 0,5]$, $h=[0; 1]$, $\gamma=[0\div 0,1]$, $\lambda=[0,05\div 0,3]$.

МРО эффективно находят оценки коэффициентов модели при следующих интервалах значений параметров: $n=[20\div 200]$, $p=[2\div 7]$, $\alpha=[1\div 2]$, $\sigma^2=[0,01\div 0,4]$, $h=[0; 1]$, $\gamma=[0\div 0,1]$, $\lambda=[0,2\div 0,3]$.

МНК эффективен в диапазонах изменения параметров: $n=[20\div 200]$, $p=[2\div 6]$, $\alpha=[0\div 1]$, $\sigma^2=[0,01\div 0,3]$, $h=[0; 1]$, $\gamma=[0\div 0,05]$, $\lambda=[0,05\div 0,1]$.

Обучающая выборка для нейронной сети распознавания классов МСО, МРО и МНК составлена на основе указанных интервалов и содержит $m=150$ значений. Тестовая выборка содержит 38 значений. Для приведения входных данных к единому диапазону изменения использован метод нормировки $f' = \frac{f - \min}{\max - \min}$, где f – исходное значение параметра, f' – значение, подаваемое на вход нейронной сети. Выходной вектор закодирован следующим образом: 1 – класс МСО, 2 – класс МРО, 3 – класс МНК.

Следующим этапом построения составного нейросетевого классификатора является построение нейронной сети для выбора подкласса методов. Покажем это на примере класса МСО, в котором насчитывается более 60 методов и эффективность выбора метода во многом определяется принадлежностью его к подклассу гребневого, сжатого, обобщенного гребневого оценивания и оценок дробного ранга. Многообразие методов и подходов к выбору их фактора деформации определяет разделение указанных методов на подклассы. Кроме этого, разделению на подклассы способствовали различные вычислительные свойства методов: эффективность, точность, быстродействие, смещение вектора оценок, дисперсия оценок, среднеквадратичная ошибка модели, вычислительная сложность, что в свою очередь во многом определяет область их использования для решения различных прикладных задач.

Проведем анализ результатов, полученных при модельном эксперименте распознавания подклассов гребневого, сжатого, обобщенного гребневого оценивания и оценок дробного ранга в классе МСО. На основании анализа литературных источников [1, 2, 4] и проведения серии экспериментов был определен набор параметров, позволяющих максимально точно произвести разделение подклассов методов смещенного оценивания, а также интервалы изменения этих параметров:

C_1 – определитель информационной матрицы $X'X$, умноженный на количество независимых переменных, ($\Delta p = [0,0001; 10]$);

C_2 – размах $X'X$, умноженный на объем выборки ($S_n = [1,5994; 6,8501]$);

C_3 – показатель обусловленности матрицы $X'X$, ($C = [0,1; 7]$);

C_4 – дисперсия помех, умноженная на определитель матрицы $X'X$, ($\sigma^2 \Delta = [0; 1]$);

C_5 – показатель нормы 1 [4], умноженный на объем выборки: $nH_1 = [2,311; 8,4531]$;

C_6 – показатель нормы 2 [4], $H_2 = [1,3869; 5,1052]$.

Совокупность характеристик C_1, \dots, C_6 является входным вектором обучающей выборки для нейронной сети, предназначенной для выбора подкласса методов смещенного оценивания. Для решения задачи распознавания подклассов МСО была промоделирована работа различных типов нейронных сетей. По критерию средней относительной ошибки обучения и критерию суммарной квадратической ошибки и на основании обучающей выборки C_{1i}, \dots, C_{6i} , $i = \overline{1, m}$, наилучший результат был достигнут нейронной сетью встречного распространения.

Завершающим этапом построения составного нейросетевого классификатора по выбору эффективного метода является построение нейронной сети, осуществляющей выбор метода оценки параметров модели на основании некоторой совокупности критериев эффективности [2–6].

Рассмотрим формирование обучающей выборки для нейронной сети, используемой для выбора эффективного метода оценивания. Для каждого метода в классе МСО, МРО и МНК рассчитываются различные критерии эффективности. Для класса МСО – критерий относительной среднеквадратичной погрешности, критерий, характеризующий дисперсию оценок коэффициентов модели, критерий, характеризующий смещение оценок коэффициентов модели, стандартный критерий среднеквадратичной ошибки модели, критерий максимальной абсолютной координатной ошибки метода, критерий максимальной координатной относительной ошибки метода [2, 5]. При этом критериям эффективности назначаются весовые коэффициенты в зависимости от типа решаемой задачи и от цели исследования. Для класса МРО рассчитываются значения критерия относительной среднеквадратической ошибки модели и критерия относительной медианы абсолютных отклонений [3, 5, 6]. Для МНК – среднеквадратической ошибки модели. Выбор метода в каждом классе происходит по максимальному количеству минимальных значений критериев.

То есть, на последнем этапе классификации мы получаем метод, который позволяет наиболее эффективно оценить параметры математической модели процесса на основании статистических характеристик входной информации, а это в свою очередь дает возможность построить адекватную модель исследуемого процесса. Для оценки точности предложенного составного нейросетевого классификатора с помощью выбранного классификатором метода, рассчитывается оценка параметров математической модели и сравниваются полученные оценки с заданными истинными оценками. Далее производится проверка адекватности полученной математической модели на основании статистических критериев: коэффициента детерминации, F -критерия Фишера, значения t -статистики.

Таким образом, в статье предложена методика построения составного нейросетевого классификатора по выбору эффективного метода построения математической модели процесса автоматизации в зависимости от внутренней структуры его выборочных значений. На основании указанной методики разработан метод построения составного нейросетевого классификатора, обеспечивающий выбор наиболее эффективного метода оценивания параметров математической модели для процессов, исходные данные которых подвержены влиянию линейной зависимости и зашумленности. Данный классификатор позволяет определить метод, обеспечивающий минимальную среднеквадратическую ошибку математической модели процесса, что в свою очередь определяет ее адекватность.

Список литературы: 1. Вучков И., Бояджиева Л., Солаков Е. Прикладной линейный регрессионный анализ. Пер. с болгар. - М.: Финансы и статистика, 1987. - 230 с. 2. Шатовська Т.Б. Математичні моделі визначення ефективності методів зміщеного оцінювання: Автореф.дис... к-та техн. наук: 01.05.02 / Харк. держ. техн. ун-т радіоелектроніки. - Х., 2000. - 19 с. 3. Антонов В.О. Моделі та алгоритми визначення ефективних робастних методів при синтезі функціональних задач АСУ: Автореф.дис... к-та техн. наук: 05.13.06 / Харк. держ. техн. ун-т радіоелектроніки. - Х., 2000. - 20 с. 4. Casella B.G. Minimax ridge regression estimation. - Annals of Statistics, 1980, vol. 8, w.5, p. 1036-1056. 5. Лесная Н.С., Ренка В.Б., Шатовская Т.Б. Методика выбора эффективного метода оценивания параметров моделей объектов при решении функциональных задач АСУ // Вестник Херсонского гос. техн. ун-та. - 2001. - № 1(10). - С. 284-286. 6. Смоляк С.А., Титаренко Б.П. Устойчивые методы оценивания: Статистическая обработка неоднородных совокупностей. - М.: Статистика, 1980. - 208 с.