

Розробка і створення перспективних конструкцій машин та механізмів на базі мехатронних технологій

УДК 621.9.01

А.Г. ДЕРЕВЯНЧЕНКО (д-р техн. наук, проф., зав. каф.)

А.А. ФОМИН (канд. техн. наук, доц.)

О.В. ФОМИНА (асп.)

Одесский национальный политехнический университет, г. Одесса, Украина

ПОВЫШЕНИЕ КАЧЕСТВА СИСТЕМЫ ПОДДЕРЖАНИЯ РАБОТОСПОСОБНОСТИ ИНСТРУМЕНТОВ С ИСПОЛЬЗОВАНИЕМ НЕЧЕТКОГО НЕЙРОСЕТЕВОГО КЛАССИФИКАТОРА ИХ СОСТОЯНИЙ

Разработан нечеткий нейросетевой классификатор состояний режущих инструментов. Проведены исследования качества его работы.

нейронная сеть, классификатор, режущие инструменты, работоспособность

Введение

Качественное функционирование автоматизированных и автоматических станочных комплексов невозможно без использования систем поддержания работоспособности (СПР) их основных элементов [1]. Доля отказов таких комплексов по причине отказов режущих инструментов (РИ) для ряда условий обработки превышает 50 %. Поэтому необходимость создания систем класса СПР РИ [2] не вызывает сомнений. Перспективным путем повышения качества СПР РИ является использование в их структуре комплекса взаимосвязанных средств искусственного интеллекта, одним из которых является классификатор состояний инструментов. В работе [3] приведены результаты разработки классификатора, основанного на применении комбинированного метода построения решающего правила статистической классификации для многоальтернативного распознавания состояний РИ и адаптивного метода обучения. Длительная его апробация показала, что в условиях ограниченного объема статистической информации о состояниях РИ степень нечеткости их классификации достаточно велика. Поэтому возникла необходимость разработки альтернативного варианта – нечеткого нейросетевого классификатора состояний инструментов. Целью статьи является изложение результатов разработки нечеткого нейросетевого классификатора состояний РИ и оценки качества его работы.

Основная часть

Одним из современных средств решения задач распознавания состояний объектов различной природы являются нейронные сети (НС) [4]. Рассмотрим задачу построения нечеткого нейросетевого классификатора состояний режущей части РИ, на вход которого подается вектор признаков, формируемых системой технического зрения (СТЗ).

Для распознавания состояний РИ могут строиться НС различной сложности: однослойные, двухслойные с различным количеством нейронов. С ростом сложности структуры сети растет время ее обучения.

Для обучения НС с учетом особенностей решаемой задачи целесообразно использовать алгоритма обратного распространения ошибки распознавания [4]. Этот

алгоритм выбран потому, что позволяет заранее задавать требуемую точность классификации.

Для формирования сети выбран набор средств NEURAL NETWORKS TOOLBOX в системе MATLAB.

Для обучения сети эксперту необходимо сформировать обучающую выборку $U_{\Sigma\Omega}^L$, включающую наборы векторов по каждому классу состояний РИ ($\Omega_I^L, \Omega_{II}^L, \dots, \Omega_N^L$), где N – число классов состояний РИ. Например, элементарная выборка для 1-го класса состояний РИ имеет вид:

$$U_{\Omega_I}^L = \left[\begin{array}{c} x_1^L = (x_{11}^L, x_{12}^L, \dots, x_{1j}^L, \dots, x_{1n}^L) \\ x_2^L = (x_{21}^L, x_{22}^L, \dots, x_{2j}^L, \dots, x_{2n}^L) \\ \vdots \\ x_i^L = (x_{i1}^L, x_{i2}^L, \dots, x_{ij}^L, \dots, x_{in}^L) \\ \vdots \\ x_k^L = (x_{k1}^L, x_{k2}^L, \dots, x_{kj}^L, \dots, x_{kn}^L) \end{array} \right],$$

где: n – число признаков в составе вектора состояния, k – число векторов в элементарной выборке (выборке по каждому классу).

В состав $U_{\Sigma\Omega}^L$ входят признаки формы зоны износа. Использование выборки с большим количеством признаков (12) нецелесообразно. Поэтому проводился анализ их информативности, который позволил выбрать в качестве основных второй и седьмой признаки формы зоны износа задней поверхности резцов.

Разработан нечеткий нейросетевой классификатор для распознавания состояний резцов (далее – РИ), структура которого отображена на рис. 1.

Классификатор работает по следующему гибридному двухуровневому алгоритму. На первом уровне экспертом (при работе классификатора в автоматизированном режиме) подается на вход сети обучающая выборка $U_{\Sigma\Omega}^L$. На выходе сети формируются результат классификации – номер класса (y) по каждому состоянию (вектору признаков). В обобщенной форме:

$$y_{\Sigma}^L = \left[\left(y_{\Omega_1^L}^1, y_{\Omega_1^L}^2, \dots, y_{\Omega_1^L}^i, \dots, y_{\Omega_1^L}^k \right), \dots, \left(y_{\Omega_N^L}^1, y_{\Omega_N^L}^2, \dots, y_{\Omega_N^L}^i, \dots, y_{\Omega_N^L}^k \right) \right].$$

Кроме того, определяются параметры качества – процент или вероятность правильного распознавания (ППР, ВПР), значения ошибок первого и второго рода. Если заданное качество не получено, выполняется поиск векторов состояний, неверно классифицированных. Далее начальная обучающая выборка переформировывается с добавлением нового признака – степени нечеткости классификации ($x_{(n+1)}^L$), т.е. создается новая обучающая выборка $\tilde{U}_{\Sigma\Omega}^L$:

$$\tilde{U}_{\Sigma\Omega}^L = x_{\Sigma}^L = \left[\left(x_{11}^L, \dots, x_{1j}^L, \dots, x_{1n}^L, x_{1(n+1)}^L \right), \dots, \left(x_{k1}^L, \dots, x_{kj}^L, \dots, x_{kn}^L, x_{k(n+1)}^L \right) \right].$$

Затем повторяется процесс обучения сети (реализуется второй уровень гибридного алгоритма). После получения требуемого качества выполняется запись результатов в соответствующую базу данных.

Покажем результаты работы классификатора и гибридного алгоритма на примере решения задачи распознавания двух классов состояний режущей части (РЧ) с использованием двух признаков и соответствующей обучающей выборки.

При формировании обучающей выборки эксперт указывает на принадлежность каждого вектора состояний к определенному классу. Результаты обучения однослойной нейронной сети на 1-м этапе (первая ветвь гибридного алгоритма) показаны на рис. 2, а параметры качества распознавания – на рис. 3.

Результат получен за 20 итераций.

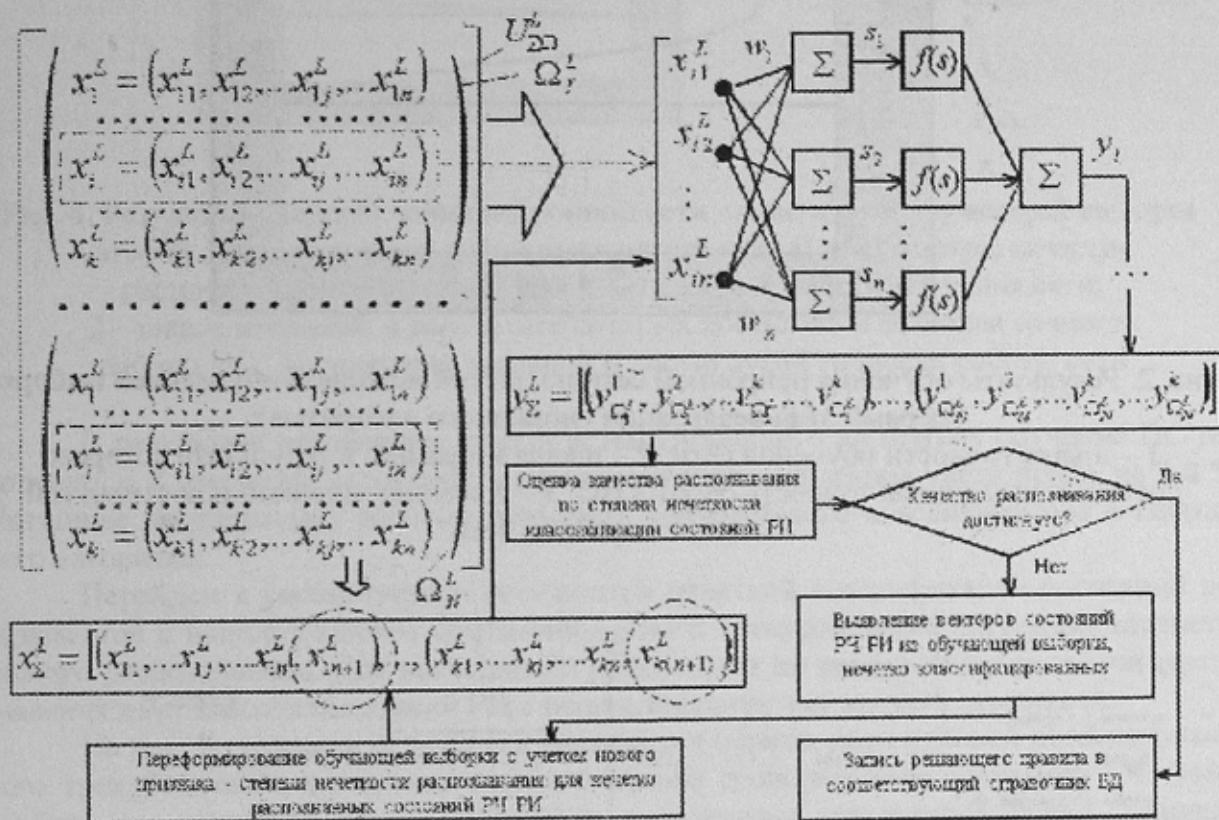


Рис. 1. Структура нечеткого классификатора состояний режущей части РЧ, реализующего гибридный двухуровневый алгоритм распознавания

На рис. 3, а приняты следующие обозначения: 1 – состояния РЧ 1-го класса, правильно (четко, однозначно) классифицированные нейронной сетью; 2 – состояния РЧ 2-го класса, правильно классифицированные НС; 3 – состояние РЧ, нечетко классифицированное НС; вероятность его принадлежности ко второму классу составляет 69,52%, к 1-му классу – 30,48%; 4 – состояние РЧ, нечетко классифицированный нейронной сетью; вероятность его принадлежности ко второму классу составляет 48,52%, к 1-му классу – 51,48%. Согласно рис. 3, б. качество распознавания недостаточно высокое. Поэтому есть необходимость реализации второй ветви гибридного алгоритма.

Эксперт (при работе классификатора в автоматизированном режиме) подает на вход сети выборку \tilde{U}_Σ^L . В рассматриваемом примере в каждый вектор состояния РЧ для каждого класса добавляется признак – степень нечеткости распознавания.

Результаты переобучения сети показаны на рис. 4.

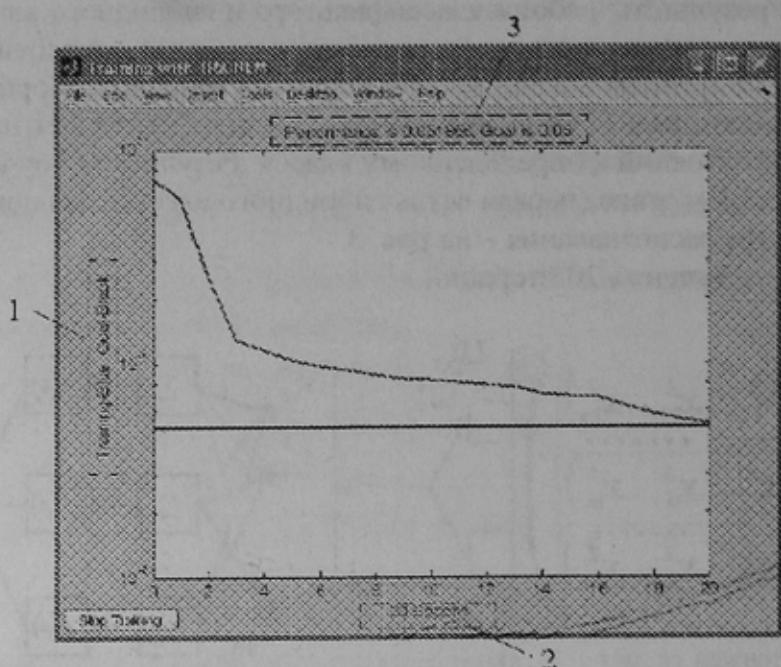


Рис. 2. Результаты обучения нейронной сети по четкой исходной обучающей выборке (первый этап реализации гибридного алгоритма):

1 – шкала точности обучения сети; 2 – шкала итераций, в результате которых достигается заданная точность работы НС; 3 – значения заданной и достигнутой точности работы сети

```

Columns 1 through 9
 0.0918   0   0.2195   0.2150   0.1070   0.1085   0   0   0.0566   err1 = 2

Columns 10 through 18
 0.3939   0.4602   0.2175   0   0   0   0   0.0760   0.2191   err2 = 2

Columns 19 through 27
 0.1134   0   0.0948   1.0000   0.9918   1.0000   1.0000   1.0000   0.6681   err3 = 2

Columns 28 through 36
 0.4652   0.8473   1.0000   1.0000   1.0000   0.9819   1.0000   1.0000   1.0000   P = 1

Columns 37 through 45
 1.0000   1.0000   1.0000   0.9778   1.0000   0.6952   0.4602   1.0000   0.7352   P = 1

Columns 46 through 49
 1.0000   1.0000   0.4559   0.5521   4   3   5

```

Рис. 3. Результаты реализации первого этапа гибридного алгоритма: оценки принадлежности состояний РИ к классам (а), ошибки 1-го, 2-го рода и ВПР (б)

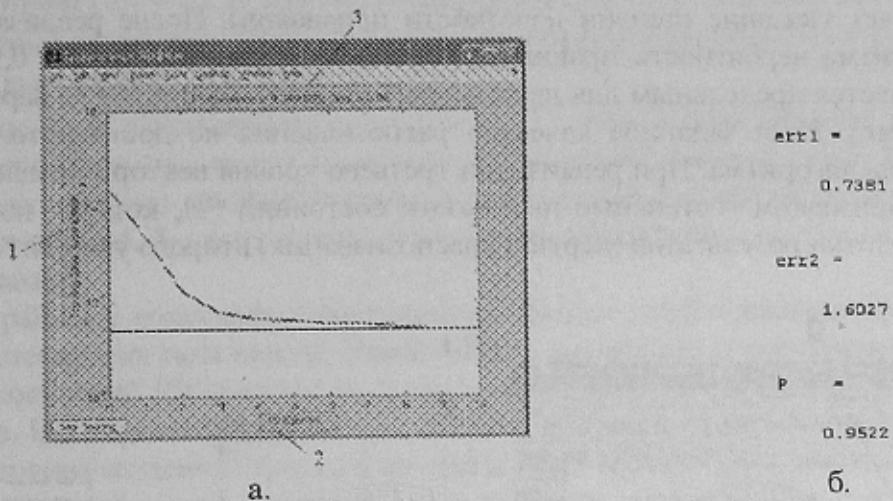


Рис. 4. Результаты переобучения нейронной сети по нечеткой обучающей выборке – второй этап реализации гибридного алгоритма (а) и параметры качества распознавания состояний РИ (б): 1 – шкала точности обучения сети; 2 – шкала итераций, в результате которых достигается заданная точность работы НС; 3 – значения заданной и достигнутой точности работы сети

В результате реализации второй ветви гибридного алгоритма обучение НС выполнено за 8 итераций, вероятность правильного распознавания увеличилась на 3-4 %. Указанное подтверждает работоспособность нейросетевого классификатора и гибридного алгоритма.

Перейдем к рассмотрению результатов нечеткой классификации состояний инструментов с использованием комбинированного трехуровневого алгоритма статистического распознавания. Для наглядности результатов он реализован для задачи распознавания двух классов состояний РИ с использованием тех же двух признаков.

На рис. 5 показаны результаты реализации первых двух уровней комбинированного трехуровневого алгоритма статистического распознавания состояний РЧ. Здесь отображены четкие и нечеткие решения, полученные при распознавании. Приняты следующие обозначения: I – зона четкой классификации векторов состояний РЧ РИ класса 1; II – зона четкой классификации векторов состояний РЧ РИ класса 2, V – решающее правило, полученное в результате реализации первого уровня алгоритма (первая, приближенная картина распознавания). Оно является стартовым для реализации второго уровня алгоритма.

В пространстве между зонами I и II находятся нечетко распознанные вектора состояний РЧ. Границы степени нечеткости определяют соответствующие линии – эквипотенциалы, характерные постоянным уровнем нечеткости. Из десяти эквипотенциалов уровней нечеткости на рисунке обозначены уровни 0,1 и 0,5.

На рис. 5, б приведены результаты распознавания с использованием первых двух ветвей алгоритма (нечеткость игнорируется). При обучение системы по методу статистических решений (МСР) [5, 6] вероятность правильного распознавания составила 0,87 (рис. 5, б, зоны 1, 2). Дело в том, что МСР работает только с четкими значениями признаков (нечеткость игнорируется, т.к. структура метода статистических решений изначально не предусматривает наличие нечеткости). Результаты МСР являются основой для реализации второго уровня алгоритма – с использованием метода стохастической аппроксимации – МСА [5, 6]. Как и на первом уровне алгоритма, указания о степени нечеткости отдельных векторов состояний РЧ РИ отсутствуют (хотя структура

МСА допускает указание степени нечеткости признаков). После реализации второго уровня алгоритма вероятность правильного распознавания составляет 0,925. Данный результат является предельным для двух первых уровней алгоритма (в варианте четкой его реализации). Если заданное качество распознавания не достигнуто, запускается третий уровень алгоритма. При реализации третьего уровня вектор признаков пополняется новым признаком – степенью нечеткости состояний РИ, которая получена в результате обработки результатов (картины распознавания) второго уровня.

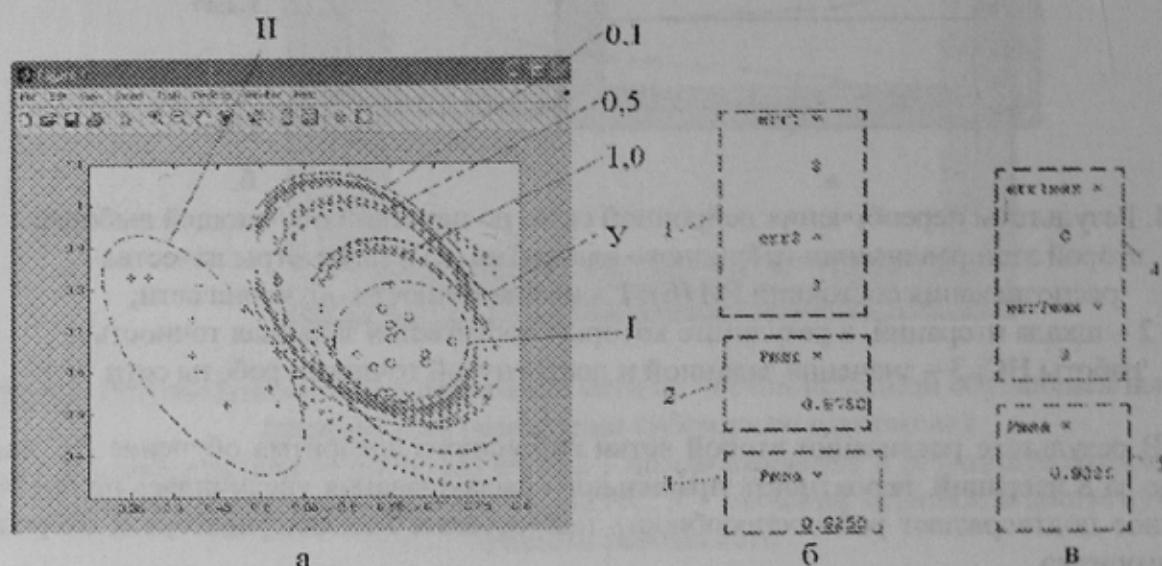


Рис. 5. Графическое представление влияния степени нечеткости классификации (при реализации комбинированного метода статистического распознавания) на положение и форму решающего правила (а) и и показатели качества распознавания при реализации комбинированного алгоритма статистического распознавания без оценки (б) и с оценкой степени нечеткости признаков (в)

В результате реализации третьего этапа вероятность правильного распознавания составляет 0,935. Улучшение качества по сравнению со вторым уровнем составляет 0,01.

При реализации третьей ветви алгоритма степень нечеткости признаков вводилась экспертом, причем она была указана не для всех, а только для признаков с высокой ошибкой классификации. Поэтому здесь есть резервы для дальнейшего повышения качества. При автоматическом вычислении степени нечеткости она рассчитывается для всех векторов обучающей выборки, начиная с "порога четкости" (Q). Остановимся на принципе назначения порога четкости для каждого из распознаваемых классов. Порог предполагает наличие доверительных интервалов – окрестностей четких значений классификации. Введем параметр F степени принадлежности вектора состояния к классу. Если значения функции принадлежности заданы следующим образом: 0 – для первого класса, 1 – для второго класса, то доверительные интервалы выбираются из следующих соображений. Если $Q = 0 \dots 0,05$ (а в общем случае $Q < 0,05$ – т.к. при построении картины распознавания значения функции принадлежности могут здесь быть и отрицательными), то считаем класс 1 четко классифицированным ($F_1 = 1$). Если $Q = 0,95 \dots 1,0$ (а в общем случае $Q > 0,95$ – т.к. при построении картины распознавания значения функции принадлежности могут превышать 1), то считаем класс 2 четко клас-

сифицированным ($F_2 = 1$). В случае, когда $0,05 \leq Q \leq 0,95$, считаем вектор (состояние РЧ) распознанным нечетко. При этом для назначения степени нечеткости используются следующие выражения: $F_1 = 1 - Q$; $F_2 = Q$.

На рис. 5, б, в принятых обозначениях: 1, 2 – результаты качества распознавания при реализации первого уровня (нечеткость признаков игнорируется); 3 – результаты качества распознавания при реализации второго уровня алгоритма (нечеткость признаков игнорируется); 4, 5 – результаты качества распознавания с оценкой степени нечеткости признаков.

При работе с нечеткими признаками возникает необходимость предварительного анализа степени их нечеткости. Такой анализ двумерных и трехмерных пространств признаков состояний РЧ показал наличие пересечений зон, соответствующих различных классов. Вектора состояний, попадающие в эти зоны, отображают некоторые переходные состояния из одного класса в другой и распознаются нечетко. Поэтому требуется предварительный анализ статистических выборок, используемых для обучения нейросетевого классификатора.

На рис. 6, а приведен общий вид панели программы анализа статистических выборок. В левой верхней ее части индицируется количество классов состояний РИ, размер обучающей выборки, автоматически определяемые программой при ее анализе. На рис. 6, б приведено укрупненное изображение ее окна.

В правой части панели находится окно номера анализируемого признака и имеется флагок для его выбора. Зона 1 панели отображает цветовую индикацию номеров классов состояний РЧ, что обеспечивает наглядность изображения: класс 1 – черный; класс 2 – красный; класс 3 – зеленый; класс 4 – синий; класс 5 – розовый.

Зона 2 (окно) панели отображает результаты анализа признаков. Приняты следующие обозначения: 1 – нечеткая классификация для 5 классов; 2 – степень принадлежности признака к классу (степень нечеткости); 3 – номер признака. Горизонтальные участки диаграмм для каждого признака отображают ту под область значений признаков, которые распознаются четко (ВПР = 1). Наклонные участки соответственно отображают под области с различной степенью нечеткости.

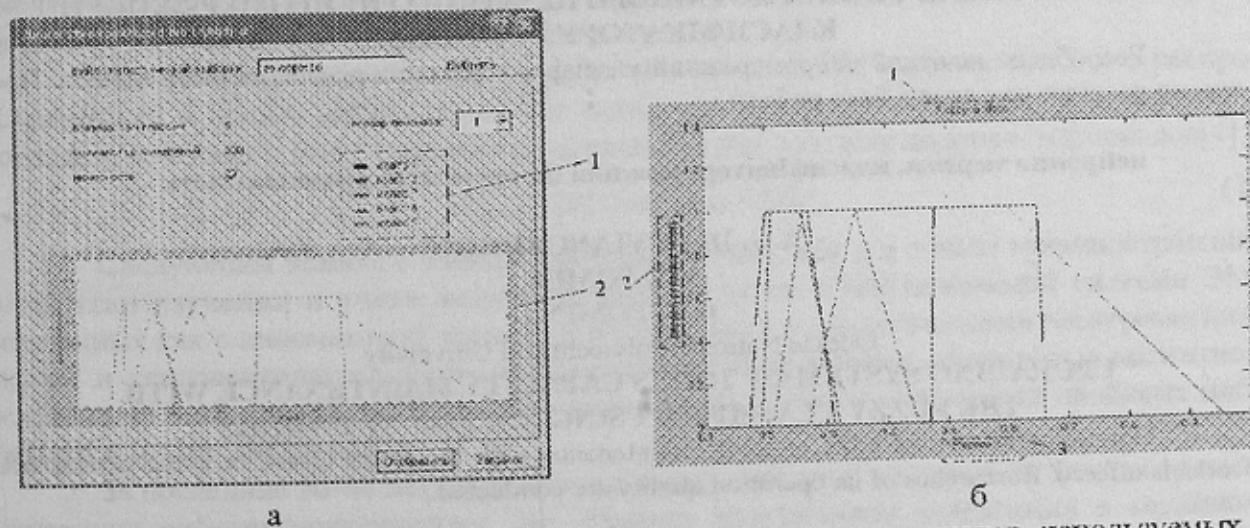


Рис. 6. Общий вид панели для оценки степени нечеткости признаков, используемых для распознавания состояний РЧ (а) и укрупненное изображение окна с результатами анализа степени нечеткости признаков состояний РЧ РИ (б)

Выводы

Разработан нечеткий нейросетевой классификатор состояний РИ и двухуровневый гибридный алгоритм его реализации.

Классификатор обеспечивает качественное распознавание состояний инструментов в условиях ограниченного объема статистической информации.

Применение классификатора будет способствовать повышению качества функционирования СПР РИ.

Список литературы

1. Старков В.К. Обработка резанием. Управление стабильностью и качеством в автоматизированном производстве / В.К. Старков. – М.: Машиностроение. 1989 – 296 с.
2. Формирование диагностической информации для систем поддержания работоспособности режущих инструментов / А.Г. Деревянченко, А.А. Фомин, Д.А. Криницын та ін. // Наукові праці Донецького національного технічного університету. Серія: Машинобудування і машинознавство. – 2008. – Випуск 5(139). – С. 101–106.
3. Методы и средства построения классификатора состояний режущих инструментов / А.Г. Деревянченко, В.Д. Павленко, А.А. Фомин та ін. // Современные технологии в машиностроении: к юбилею Ф.Я. Якубова. Сборник научн. статей – Х.: НТУ “ХПИ”, 2007. – С. 46–55.
4. Уоссерман Ф. Нейрокомпьютерная техника / Ф. Уоссерман. – М.: Мир, 1992 – 184 с.
5. Вапник В.Н. Теория распознавания образов (статистические проблемы обучения) / В.Н. Вапник, А.Я. Червоненкис. – М.: Наука, 1974. – 415 с.
6. Прикладная статистика. Классификация и снижение размерностей / С.А. Айвазян, В.М. Бухштабер, И.С. Енюков, Л.Д. Мешалкин. – М.: Финансы и статистика, 1989 – 607 с.

**О.Г. ДЕРЕВЯНЧЕНКО
О.О. ФОМИН
О.В. ФОМИНА**

Одеський національний політехнічний університет
**ШДВІЩЕННЯ ЯКОСТІ СИСТЕМИ ШДТРИМКИ ПРАЦЕЗДАТНОСТІ
ІНСТРУМЕНТІВ З ВИКОРИСТАННЯМ НЕЧІТКОГО НЕЙРОМЕРЕЖНОГО
КЛАСИФІКАТОРУ ЇХ СТАНІВ**

Розроблено нечіткий нейромережний класифікатор станів різальних інструментів. Продедено дослідження якості його роботи.

нейронна мережа, класифікатор, різальні інструменти, працевздатність

**A.G. DEREVIANCHENKO
A.A. FOMIN
O.V. FOMINA**

Odessa National Polytechnical University
**UPGRADING SYSTEM OF TOOLS CAPACITY MAINTENANCE WITH
THE FUZZY CLASSIFIER USING NEURON NETWORKS**

Upgrading system of tools capacity maintenance with the fuzzy classifier using neuron networks is offered. Researches of its operation quality are conducted.

neuron network, classifier, cutting tools, working capacity