

НЕЙРОСЕТЕВАЯ МОДЕЛЬ ПРОГНОЗА ОШИБОЧНЫХ ДЕЙСТВИЙ ЛЁТЧИКОВ

© 2011 А. Н. Даниленко

Самарский государственный аэрокосмический университет
имени академика С.П. Королёва (национальный исследовательский университет)

Предлагается модель гибридного нейронечёткого классификатора со встроенной функцией прогноза ошибочных действий лётчика. Проведено исследование построенной сети на реальных и тестовых выборках.

Прогноз, ошибочные действия лётчика, интеллектуальная поддержка, гибридный нейронечёткий классификатор, двуслойный перцептрон, малые выборки.

Ошибка лётчика как фактор снижения безопасности полёта на всём протяжении истории авиации была предметом внимания лётно-технического и руководящего персонала авиакомпаний, научных работников в области психологии. Долгое время признать факт ошибки лётчика означало признать его виновным в невыполнении задания, в поломке техники и собственной гибели. Отсюда все мероприятия по борьбе с ошибками были направлены на профессиональный отбор, обучение и воспитание (наказание). Эти меры, очевидно, необходимы, но недостаточны, поскольку ошибки совершают отобранные многолетней практикой, квалифицированные лётчики, что позволяет предположить, что человеческий фактор аварийности не сводится к проблеме профессиональной непригодности.

Деятельности лётчика присуща необычная для других профессий пространственная ориентировка. Оценку положения самолёта в пространстве лётчик осуществляет визуально по наземным ориентирам и по приборам, а при отсутствии видимости земли в сложных метеоусловиях – только по приборам. Качество взаимодействия лётчика с приборами летательного аппарата во многом определяется его индивидуально-психологическими особенностями.

Особое место в перечне причин авиакатастроф занимают ошибочные действия, связанные с психологическими свойствами личности. Представляет интерес роль самооценки и стрессовой напряжённости в воз-

никновении ошибочных действий и её влияние на профессиональную эффективность лётчиков в целом [1].

Исследование проводилось в авиационной эскадрилье. На основе данных, полученных с помощью психологического тестирования, был создан диагностический комплекс прогноза профессиональной эффективности лётчиков.

Пусть каждый человек описывается конечным набором признаков [2], в рассматриваемом случае это характеристики, полученные с помощью психодиагностики: $A = \{A_1, A_2, \dots, A_n\}$, где $n = \overline{1, 55}$. Каждому признаку A_i соотносится универсальное множество U_i , состоящее из лингвистических переменных и числовых значений $\{a_{1i}, a_{2i}, \dots, a_{ni}\}$, где $i = \overline{1, n}$.

В свою очередь, у каждого элемента данного множества существует своя функция принадлежности $\mu_{aji}(U_i)$. Имеется множество результатов $R = \{R_1, R_2, \dots, R_k\}$, где $k = \overline{1, 4}$. $R = \{\text{Не подходит, Частично подходит, В основном подходит, Подходит}\}$.

Нечёткая база правил в общем виде будет иметь следующий вид:

ЕСЛИ $(A_1 = a_{i11}^1, A_2 = a_{i22}^1, \dots, A_n = a_{inn}^1)$,

ТО $(\mu_{R1} = \mu_1^1, \mu_{R2} = \mu_2^1, \dots, \mu_{Rk} = \mu_k^1)$;

ЕСЛИ $(A_1 = a_{i11}^2, A_2 = a_{i22}^2, \dots, A_n = a_{inn}^2)$,

ТО ($\mu_{R1} = \mu_1^2, \mu_{R2} = \mu_2^2, \dots, \mu_{Rk} = \mu_k^2$);

...

ЕСЛИ ($A_1 = a_{i11}^r, A_2 = a_{i22}^r, \dots, A_n = a_{inn}^r$),

ТО ($\mu_{R1} = \mu_1^r, \mu_{R2} = \mu_2^r, \dots, \mu_{Rk} = \mu_k^r$),

где μ_{Rl} - степень принадлежности правила к классу R1.

Традиционным методом прогнозирования в психологии выступает регрессионный анализ. При этом предполагается, что значения временного ряда представляют собой случайную функцию времени, и задача заключается в верной идентификации модели. Выбор того или иного вида функции не формализован и целиком зависит от опыта эксперта.

В то же время нейронная сеть выступает в качестве универсального аппроксиматора обучающих данных, поэтому применение нейронных сетей для прогнозирования является весьма перспективным.

Кроме того, нейронную сеть можно рассматривать как адаптивную модель, поскольку она может дообучаться при поступлении новых сведений. Поведение человека по своей природе является эволюционирующим, и использование статичных моделей приводит к ухудшению качества прогноза.

Ещё одна проблема заключается в потребности большого объёма исходных данных для обучения сети. Обычно предполагается, что временной ряд содержит, как минимум, сотни значений. Для рассматриваемой задачи такой объём наблюдений невозможен. Однако существуют возможности обучения нейронной сети и при малых объёмах исходных данных. В этом случае используется многократное обучение на одних и тех же примерах, а также различные приёмы обработки временного ряда, позволяющие расширить обучающую выборку.

Особенность поставленной задачи заключается в том, что входным вектором для сети прогноза не могут являться отдельные значения самооценки лётчика или уровня стресса. На вход поступает вектор значения

динамики профессиональной пригодности за период от полугода до двух лет (то есть от 3 до 12 замеров, тестирование проводится не чаще, чем раз в два месяца). Под динамикой профессиональной пригодности понимается степень принадлежности кандидата одному из четырёх классов: кандидат полностью соответствует требованиям специальности, в основном соответствует, частично соответствует и не соответствует, которая, в свою очередь, получается при анализе 55 психологических характеристик.

Поскольку информация, на основе которой принимается решение о профпригодности кандидата, является результатами различных психологических методик, классифицируемые данные являются неточными или недостаточно определёнными. В связи с этим возникает необходимость использования нечёткой логики и теории нечётких множеств как эффективных подходов к решению данной проблемы.

Для решения всех вышеописанных задач была разработана модифицированная модель гибридного нейронечёткого классификатора со встроенной функцией прогноза.

Архитектура для решения задач нечёткой классификации предложена в [3]. Одна из возможных структур гибридного нейронечёткого классификатора представлена на рис. 1.

Нейронечёткая сеть состоит из четырёх слоёв.

Элементы первого слоя реализуют операцию фuzziфикации, т.е. формируют степени принадлежности входных переменных к определенным для них нечётким множествам

A_{ij} :

$$\mu_{A_{ij}}(x'_j) = \exp\left[-\frac{1}{2}\left(\frac{x'_j - c_{ij}}{\sigma_{ij}}\right)^2\right], \quad (1)$$

где c_{ij}, σ_{ij} – параметры функции принадлежности колоколообразного типа.

Начальные значения этих параметров установлены таким образом, чтобы функции




Рис. 1. Структура гибридного нейронечёткого классификатора

принадлежности удовлетворяли свойствам полноты, нормальности и выпуклости. Значения C_{ij} должны быть равномерно распределены в области входных векторов x . Значения данных параметров корректируется в процессе обучения сети, основанном на градиентном методе.

Каждый элемент второго слоя является нейроном «И». Они выполняют агрегирование степеней истинности предпосылок каждого правила базы в соответствии с операцией T-нормы по формулам

$$\begin{aligned} \alpha_1 &= \min \{A_{11}(x_1), A_{12}(x_2), \dots, A_{1n}(x_n)\}; \\ \alpha_2 &= \min \{A_{21}(x_1), A_{22}(x_2), \dots, A_{2n}(x_n)\}; \\ &\dots \\ \alpha_n &= \min \{A_{n1}(x_1), A_{n2}(x_2), \dots, A_{nn}(x_n)\}. \end{aligned} \tag{2}$$

Элементы третьего слоя выполняют агрегирование степеней истинности предпосылок каждого правила базы в соответствии с операцией S-нормы.

Для решения поставленной задачи классификации соискателей на замещение вакантных должностей на основе психодиагностики объём входной выборки доволь-

но мал и составляет в среднем 50 значений. С целью ускорения работы алгоритма обучения сети и его упрощения заменим нейроны третьего слоя на нейроны, которые выполняют нормализацию и вычисляют следующие значения:

$$\begin{aligned} \beta_1 &= \frac{\alpha_1}{\alpha_1 + \alpha_2 + \dots + \alpha_n}; \\ \beta_2 &= \frac{\alpha_2}{\alpha_1 + \alpha_2 + \dots + \alpha_n}; \\ &\dots \\ \beta_n &= \frac{\alpha_n}{\alpha_1 + \alpha_2 + \dots + \alpha_n}. \end{aligned} \tag{3}$$

Элементы четвёртого слоя вычисляют значения заключений по каждому правилу:

$$\begin{aligned} y_1' &= B_1^{-1}(\alpha_1) = a_1 + \frac{1}{b_1} \ln \frac{1 - \alpha_1}{\alpha_1}; \\ y_2' &= B_2^{-1}(\alpha_2) = a_2 + \frac{1}{b_2} \ln \frac{1 - \alpha_2}{\alpha_2}; \\ &\dots \\ y_n' &= B_n^{-1}(\alpha_n) = a_n + \frac{1}{b_n} \ln \frac{1 - \alpha_n}{\alpha_n}, \end{aligned} \tag{4}$$

где a_i, b_i – нелинейные параметры функций принадлежности $\mu_{B_i}(y)$ нечётких множеств заключений правил.

Выходы нечёткой сети вычисляются следующим образом: $y_i' = \beta_i B_i^{-1}(\alpha_i)$.

Эти выходы трактуются как степени принадлежности предъявленного объекта соответствующему классу.

Так как гибридный нейронечёткий классификатор представляется в виде многослойной структуры с прямым распространением сигнала, а значение выходной переменной можно изменять, корректируя параметры элементов слоёв, то для обучения этой сети можно использовать градиентные алгоритмы.

С помощью такой нейросетевой модели решается задача классификации, результаты которой являются входным вектором для сети прогноза.

Далее к модифицированному гибриднему нейронечёткому классификатору добавляем обычный двуслойный перцептрон [4] с

помощью дополнительного нейрона, который накапливает значения классификации для входного вектора прогноза и, по сути, является разновидностью звёзд Гроссберга [5] (рис. 2). Двуслойный перцептрон был реализован без изменений.

В гибридном нейронечётком классификаторе реализован алгоритм Цукомото, а в качестве алгоритма обучения – метод обратного распространения ошибки. Выявлено влияние параметров гибридного нейронечёткого классификатора. Выбрана оптимальная структура сети: объём обучающей выборки – 35 примеров, шаг обучения сети $h=0,45$, гауссовская функция фуззификации, метод дефуззификации на основе среднего квадратичного отклонения.

Проведено исследование качества прогнозирования с помощью построенной нейронной сети на тестовых и реальных временных рядах. Для каждого временного ряда выбиралась структура сети, обеспечивающая наилучшее качество прогнозирования. Результаты приведены в таблице 1.




Рис. 2. Структура разрабатываемой сети

Таблица 1. Частота использования различных структур для двуслойного перцептрона

Число входов	K_n/s				Всего
	1%	5%	10%	15%	
2	12	7	1	2	22
3	3	8	9	11	31
4	0	0	3	1	4
5	0	0	2	1	3
Число нейронов в скрытом слое					
	1%	5%	10%	15%	Всего
2	13	15	11	10	49
3	2	0	3	4	9
4	0	0	1	1	2

Считается, что прогноз обладает достаточной точностью, если ошибка прогнозирования не превышает 20 %.

На рис. 3 показана зависимость точности прогноза от воздействия шума при использовании различных методов.

«Идеальный» прогноз – это прогноз, отклонение которого от значений ряда обусловлено только случайными факторами. Если ошибка прогноза незначительно отличается от ошибки «идеального» прогноза, то его можно считать точным.

$$K1 = \frac{\sigma_{\varepsilon}^2}{\sigma_D^2} \cdot 100\% -$$

коэффициент шум/сигнала, представляющего собой отношение мощности помехи к мощности полезного сигнала.

$$K2 = \sqrt{\frac{\sum_{t=n+1}^{n+l} (Y_t^* - Y_t)^2}{\sum_{t=n+1}^{n+l} Y_t^2 + \sum_{t=n+1}^{n+l} (Y_t^*)^2}} -$$

коэффициент несоответствия (второй коэффициент Тейла), оценивающий точность прогноза.

По результатам исследования сделан вывод о том, что прогнозы, полученные с помощью нейронной сети, обладают высокой точностью и для многих типов динамики существенно превосходят по качеству прогнозы, полученные с помощью регрессионной модели.

Кроме того, модернизированная структура гибридного нейронечёткого классификатора и алгоритм его обучения позволяют решить проблему необходимости множества замеров индивидуальных показателей, динамика которых позволила бы построить тренд и решить задачу на малых выборках.

Данный подход даёт возможность с определённой долей вероятности рассчитывать предрасположенность к ошибочным действиям в каждом конкретном случае. Используемый в организационно-управленческой деятельности, такой принцип может помочь в прогнозировании опасности, вызванной человеческим фактором.




Рис. 3. Зависимость точности прогноза от воздействия шума

Библиографический список

1. Ихсанова, С.Г. Взаимосвязь уровня притязаний и самооценки с профессиональной эффективностью летчиков [Текст] / С.Г. Ихсанова, Н.Н. Черная. – Самара: СГПУ. – 2007. - 114 с.
2. Новак, В. Математические принципы нечёткой логики [Текст] / В. Новак, И. Перфильева, И. Мочкорж. – М.: Физматлит. – 2006. - 352 с.
3. Борисов, В.В. Нечёткие модели и сети [Текст] / В.В. Борисов, В.В. Круглов, А.С. Федулов. – М.: Горячая линия – Телеком. – 2007. - 284 с.
4. Коробецкая, А.А. Автоматизированная система прогнозирования рядов экономической динамики [Текст] / А.А. Коробецкая. – Самара: СГАУ. – 2011. - 138 с.
5. Осовский, С. Нейронные сети для обработки информации [Текст] / С. Осовский / Пер. с польского И. Д. Рудинского. – М.: Финансы и статистика. – 2002. - 344 с.

**NEURAL NETWORK BASED PREDICTION MODEL
OF PILOT'S ERRONEOUS ACTIONS**

©2011 A. N. Danilenko

Samara State Aerospace University
named after academician S. P. Korolyov (National Research University)

The article presents a model of a hybrid fuzzy neural classifier with a built-in prediction function of pilot's erroneous actions. The analysis of the network constructed is performed using real and test samples.

Prediction, pilot's erroneous actions, intellectual support, hybrid fuzzy neural classifier, multilayer perceptron, small samples.

Информация об авторе

Даниленко Александра Николаевна, аспирант, ассистент кафедры программных систем, Самарский государственный аэрокосмический университет имени академика С.П. Королёва (национальный исследовательский университет). E-mail: danilenko.al@gmail.com. Область научных интересов: нечёткая логика, системы управления, человеческий фактор, принятие решений, нейронные сети.

Danilenko Aleksandra Nikolayevna, postgraduate student, assistant, department of program systems, Samara State Aerospace University named after academician S. P. Korolyov (national research university). E-mail: danilenko.al@gmail.com. Area of research: fuzzy logic, control systems, human factor, decision-making, neural networks.