

УДК 656.7:338; 656.7:658

Методика построения прогноза развития авиации общего назначения в Российской Федерации с использованием искусственных нейронных сетей

Д.О. Никитенко

Санкт-Петербургский государственный университет гражданской авиации, ул. Пилотов 38, Санкт-Петербург, Россия
dmitry.nikitenko.88@gmail.com

Статья получена 7.08.2013, принята 20.10.2013

Авиация общего назначения в России находится сегодня в зачаточном состоянии, однако ее популярность растет день ото дня, поэтому ее развитие требует непрерывного контроля и прогнозирования дальнейшего состояния. Разработка прогноза развития авиации общего назначения России – сложная проблема, требующая комплексного подхода для ее решения. Для прогнозирования изменения сложных переменных используются прогностические параметры – предикторы. В статье рассмотрен процесс формирования выборки предикторов с помощью метода экспертных оценок для построения прогноза изменения парка авиации общего назначения России. Полученная выборка скорректирована и уточнена с помощью метода корреляционного анализа. Сложные зависимости между предикторами и зависимыми переменными аппроксимируются различными методами. Обоснована целесообразность применения метода искусственных нейронных сетей для прогнозирования развития авиации общего назначения в России посредством сравнения результатов прогнозирования за прошедший период с результатами, полученными с помощью метода регрессионного анализа. Проведены предварительный анализ и нормализация входных данных. Осуществлено обучение нейронной сети выбранной структуры. Обученная сеть протестирована. Проверены точность и достоверность тестовых данных. Реализовано производство прогнозных данных с помощью обученной сети.

Ключевые слова: выборка предикторов, метод экспертных оценок, корреляционный анализ, искусственные нейронные сети, регрессионный анализ.

Technique to forecast general aviation development in the Russian Federation using artificial neural networks

D.O. Nikitenko

Saint Petersburg State University of Civil Aviation, 38 Pilotov st., Saint Petersburg, Russia
dmitry.nikitenko.88@gmail.com

Received 7.08.2013, accepted 20.10.2013

The Russian general aviation is in its infancy today, but its popularity is increasing day by day, so its development requires continuous monitoring and forecasting its future state. The Russian general aviation forecast development is a complex problem that requires a comprehensive approach to solve it. The prognostic parameters such as predictors are used to predict the change of complex variables. The article considers the predictors sample creation process using the expert estimates technique to forecast the Russian general aviation fleet changes. The resulting sample has been updated and checked up, using the correlation analysis method. Complex relationships between the predictor variables and the dependent variables are approximated by means of different methods. The appropriateness of applying the artificial neural networks method to predict the development of general aviation in Russia by comparing the forecast results for the past period with the ones obtained using the regression analysis has been proved. A preliminary analysis of the input data and their normalization has been performed. The training of the neural network of the selected structure has been implemented. The trained network has been tested. The accuracy and reliability of the test data have been checked up. The forecast data production using the trained network has been realized.

Keywords: predictors sample, expert estimates technique, correlation analysis, artificial neural networks, regression analysis.

Введение. Авиация общего назначения России – проблема и решение. Предвиденье событий дает возможность заблаговременно подготовиться к ним, учесть их положительные и отрицательные последствия и, если это возможно, вмешаться в ход развития, контролировать его и постараться воплотить в жизнь одну из альтернатив будущего.

В недавнем прошлом прогнозирование как специфический вид научного анализа находило более или менее широкое применение в области естественных явлений (прогноз погоды, паводков, урожайности). Сегодня оно охватило самые различные сферы деятельности: политику, международные отношения, экономику, научно-технический прогресс, демографические и социальные процессы, образование и т. д. [1].

Подобная популярность прогнозирования подтверждает его насущную необходимость для любой области. Авиация общего назначения (АОН) – не исключение. В СССР масштабы развития АОН впечатляли. Сейчас АОН в России зарождается заново после развала СССР, и состояние ее плачевно по сравнению с АОН развитых стран Запада. Однако популярность ее быстро растет. Прогнозирование развития АОН в России – сложнейшая проблема, решением которой в настоящее время занимаются лишь заинтересованные данным вопросом единичные специалисты или инициативные группы.

Целью их деятельности является построение прогноза развития АОН в России. Достичь данной цели в кандидатской диссертации невозможно в силу комплексности проблемы развития АОН в России. Необходимо ограничиться прогнозированием одного из ее параметров. С точки зрения авиационной техники, наиболее интересным параметром является парк ВС АОН России.

Прогнозирование изменения значений какого-либо параметра может быть осуществлено как по его известным предыдущим значениям (возможности и точность такого прогнозирования ограничены), так и по известным значениям других параметров, влияющих на его изменение. Такие параметры называются предикторами.

Построение прогноза изменения парка ВС АОН России по известным значениям предикторов подразумевает наличие статистических данных об изменении предикторов и, соответственно, об изменении парка.

Так как статистика изменения парка за длительный срок отсутствует из-за сравнительно недавнего появления АОН в России, то возможно лишь построение краткосрочного прогноза.

Для достижения данной цели необходимо решить следующие задачи:

- 1) подобрать входные данные для прогноза с использованием какого-либо метода;
- 2) проверить и уточнить полученный набор входных данных другим методом;
- 3) построить пробный прогноз с использованием выбранного метода прогнозирования;
- 4) провести оценку целесообразности применения выбранного метода прогнозирования путем построения пробного прогноза другим методом прогнозирования и сравнения результатов применения обоих методов;
- 5) провести расширенный отбор входных данных для итогового прогноза, его проверку и уточнение;
- 6) построить итоговый развернутый прогноз с использованием выбранного метода прогнозирования.

В статьях [2, 3] в качестве предикторов развития парка воздушных судов АОН России были использованы экономико-географические показатели России. Также приведены прикладные регрессионные модели, однако отсутствует итоговый прогноз, а сформированные выборки предикторов не обоснованы.

Формирование выборки предикторов развития парка воздушных судов авиации общего назначения России. Экономико-географических показателей существует огромное множество, и формирование выборки экономико-географических показателей, предикторов,

изменения парка воздушных судов АОН России – сложная и трудоемкая задача, в решении которой за короткий срок и с наименьшими трудозатратами поможет метод экспертных оценок. Целесообразно разбить всю совокупность экономико-географических показателей России на группы по направлениям. Официальные источники [4, 5] представляют 35 групп экономико-географических показателей, в каждую из которых входит до ста таких показателей. Использование подобного деления на группы значительно облегчает проведение экспертного анализа, сокращает его время и трудозатраты.

Результаты обработки оценок экспертов с помощью методов математической статистики показали, что, по мнению группы экспертов, наибольшее влияние на изменение парка воздушных судов авиации общего назначения России оказывают следующие группы экономико-географических показателей (предикторов):

– уровень жизни (вес группы 0,069, точечная оценка 7,59);

– финансы (вес группы 0,061, точечная оценка 7,55).

В данных двух группах экономико-географических показателей (предикторов) содержится в сумме 118 предикторов. Поставленная задача формирования выборки групп предикторов развития парка воздушных судов авиации общего назначения России решена, но результат ее решения требует проверки каким-либо другим методом. Задача такой проверки сводится к определению того, влияют ли предикторы из данной выборки на изменение парка ВС АОН России, и если влияют, то насколько степень их влияния значительна. Наиболее популярным методом поиска статистических взаимосвязей является метод корреляционного анализа.

Для успешного применения данного метода требуется сформировать выборку, содержащую как минимум семь значений каждого предиктора и парка воздушных судов авиации общего назначения России по годам. Данному условию удовлетворяют лишь 39 предикторов из 118. Данные по остальным неполные. Они исключены из выборки, это один из способов повышения точности дальнейшего расчета.

Статистические данные об изменении парка воздушных судов авиации общего назначения России были любезно предоставлены Федеральным агентством воздушного транспорта (ФАВТ) [6, 7]. Были получены значения парка лишь за 7 лет. В исследовании используются данные по воздушным судам иностранного производства (NGAAFМ), так как их информативность выше, чем информативность статистики по единичным экземплярам воздушных судов. Это объясняется тем, что практически во всех случаях названия единичных экземпляров воздушных судов изменяются, после чего фактически невозможно определить их реальные типы.

После соблюдения всех условий применения корреляционного анализа и всех условий использования его результатов были однозначно выявлены именно те предикторы парка воздушных судов авиации общего назначения России, которые можно использовать для дальнейших расчетов. К ним относятся следующие предикторы:

– среднедушевые денежные доходы населения;

- покупка товаров и оплата услуг;
- прирост денег на руках у населения.

Все они относятся к группе предикторов под названием «Уровень жизни». Таким образом, задача проверки результатов экспертного анализа выполнена успешно, его результаты уточнены, а выборка предикторов изменения парка воздушных судов авиации общего назначения России окончательно сформирована.

Анализ целесообразности применения метода искусственных нейронных сетей для прогнозирования развития авиации общего назначения России. Построение прогноза неизвестного значения зависимой переменной по известному значению предиктора может быть реализовано с использованием различных методов.

Новым методом, гибким, современным и нестандартным, является метод искусственных нейронных сетей. Его использование дает возможность качественно нового подхода к проблеме прогнозирования развития авиации общего назначения в России.

Решение задач с использованием метода нейронных сетей состоит из следующих этапов:

- 1) отбор входных данных;
- 2) подготовка и нормализация входных данных;
- 3) экспериментальный подбор структуры сети и параметров обучения;
- 4) обучение сети;
- 5) тестирование сети, проверка адекватности обучения;
- 6) корректировка параметров, окончательное обучение сети;
- 7) производство результатов обученной сетью [8].

При использовании метода ИНС необходимым условием является точность построения прогноза. Наиболее простым и информативным методом проверки точности является построение пробного прогноза за уже прошедший год и сравнение его результатов с известными значениями. Поэтому целесообразно разделить выборку входных данных на обучающую и не входящую в ее состав тестовую. Обучающая выборка используется для обучения сети, а тестовая – для проверки точности работы обученной сети.

Требования к входным данным для применения метода ИНС:

репрезентативность – данные должны иллюстрировать истинное положение вещей в предметной области; непротиворечивость – противоречивые данные в обучающей выборке приведут к плохому качеству обучения сети.

Выборка входных данных для построения пробного прогноза с помощью метода ИНС представляет собой значения парка ВС АОН России и его предикторов (отобранных в предыдущих разделах работы) за 7 лет, с 2006 по 2012 гг. При этом данные за 2006-2011 гг. являются обучающей выборкой, данные за 2012 год – тестовой выборкой.

Входные данные необходимо систематизировать в соответствии с требованиями применяемой программной среды для работы с ИНС.

Для решения поставленной задачи была использована программная среда, реализующая принципы ИНС, – NeuroSolutions 5.

Для работы в программе NeuroSolutions 5 входные данные, в т. ч. и названия столбцов, необходимо занести в программу «Блокнот» и сохранить в ней, т. е. перевести в формат «txt». Названия столбцов распознаются программой как названия параметров и используются в процессе работы. В полученном файле десятичная часть значений параметров отделяется знаком точки – «.», а не запятой «,». Это необходимо для корректного распознавания данных программой NeuroSolutions 5.

Фактические и желаемые значения параметров тестовой выборки следует занести в два разных файла.

Предварительная нормализация входных данных не требуется, т. к. она реализована в программе с помощью специализированного алгоритма расчета. Нормализация представляет собой проецирование входных данных на диапазон [0; 1], это делается для удобства их использования в сети [9].

Возможность нормализации данных между верхним (upper bound) и нижним (lower bound) предельными значениями имеют компоненты подачи входных данных. Каждый образец данных (sample) умножается на амплитуду (amplitude) и сдвигается на смещение (offset). Амплитуда и смещение часто называются коэффициентами нормализации (normalization coefficients). Данные коэффициенты чаще всего рассчитываются по каналам, т. е. существуют уникальная амплитуда и смещение для каждого канала. Коэффициенты хранятся в файле нормализации в той же директории, что и модель сети.

Коэффициенты нормализации рассчитываются на основе минимальных и максимальных значений, найденных во всех наборах данных, выбранных в меню DataSet Inspector (инспектор наборов данных). Все потоки данных внутри данной сети генерируются с использованием одного и того же файла нормализации. В большинстве случаев необходимо рассчитать коэффициенты на основе всех наборов данных. Это гарантирует, что все образцы данных попадут между верхним и нижним предельными значениями.

Расчет коэффициентов нормализации (амплитуды и смещения) производится по формулам (1), (2):

$$\text{Amp}(i) = (\text{UpperBound} - \text{LowerBound}) / (\text{Max}(i) - \text{Min}(i)) \quad (1)$$

$$\text{Off}(i) = \text{UpperBound} - \text{Amp}(i) * \text{Max}(i), \quad (2)$$

где $\text{Max}(i)$ – максимальное, а $\text{Min}(i)$ – минимальное значения, найденные в канале i ; UpperBound и LowerBound – значения, введенные пользователем в меню Stream Inspector (инспектор потока).

Компоненты входных данных нормализуют входные данные с использованием формулы (3):

$$\text{Data}(i) = \text{Amp}(i) * \text{Data}(i) + \text{Off}(i) [13]. \quad (3)$$

Файл нормализации также используется числовыми датчиками для денормализации данных сети, чтобы поместить их в границы исходных данных. Когда опция «Denormalize from File» в меню Probe Inspector (инспектор датчика) включена, инвертирование амплитуды и смещения применяется к каждому каналу перед выводом/записью данных. [10]

Датчики используют формулу (4) для денормализации данных:

$$Data(i) = (Data(i) - Off(i)) / Amp(i). \quad (4)$$

Структура сети и параметры обучения подбираются экспериментальным путем. Многочисленные испытания выявили, что для используемой выборки при ее объеме и содержании наиболее высокую точность показала сеть «Нечеткой логики» (CANFIS network, Fuzzy Logic) (рис. 1).

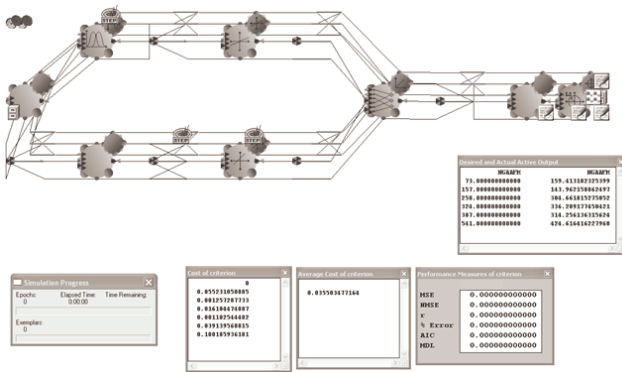


Рис. 1. Вид сети нечеткой логики, использовавшейся для расчета

Сеть нечеткой логики состоит из нечеткого аксона, расширительного синапса, нормализующего аксона, модульного синапса, объединительного аксона.

Для построения сети использовался модуль Neural Builder (строитель сетей).

Параметры обучения, при которых были получены результаты самой высокой точности, следующие:

- Membership function (функция принадлежности): Gaussian;
- Learning Rule (правило обучения): Step;
- Maximum Epochs (максимальное число эпох обучения): 150;
- Termination (окончание обучения): MSE – “Off”;
- Weight Update (обновление весов): On-Line.

Параметры обучения, не содержащиеся в списке, оставляются по умолчанию.

Кроме того, необходимо выбрать конфигурацию датчиков данной сети для отображения процессов, протекающих в сети, и их результатов. Конфигурация зависит от требуемого вида выходных данных.

Конфигурация датчиков задана следующим образом:

- Input (входные данные): DataWriter;
- Error (ошибка): DataWriter;

– Performance Measures (измерения характеристик): General – “On”.

Настройки, не содержащиеся в списке, оставляются по умолчанию.

Помимо стандартных, был добавлен датчик Data-Writer для отображения измерений Cost.

На этапе обучения в сеть загружается входная выборка, состоящая из значений входных параметров и желаемых значений выходных параметров, и запускается процесс обучения.

В процессе обучения рассчитываются различные ошибки.

Cost (издержки) представляет собой квадрат Евклидова расстояния (геометрическое расстояние в многомерном пространстве) между фактическим и желаемым выходами сети [11] и рассчитывается по формуле (5):

$$J(\tau) = \frac{1}{2} \sum_i (d_i(t) - y_j(t))^2 \quad (5)$$

где $d_i(t)$ – желаемый выход сети при данном экземпляре i ; $y_j(t)$ – фактический выход функции при данном экземпляре.

Average Cost (средние издержки) рассчитывается аналогично, но в знаменателе вместо 2 – количество экземпляров (количество измерений) в эпохе обучения.

MSE (среднеквадратическая ошибка) величина издержек дважды, рассчитывается по формуле (6):

$$MSE = \frac{\sum_{j=0}^P \sum_{i=0}^N (d_{ij} - y_{ij})^2}{NP} \quad (6)$$

где P – число выходных PE, Processing Elements (обрабатывающих элементов) [12]; N – количество экземпляров в наборе входных данных; y_{ij} – выход сети для экземпляра i обрабатывающего элемента j ;

d_{ij} – желаемый выход для экземпляра i обрабатывающего элемента j .

r – коэффициент корреляции между фактическим выходом сети и желаемым выходом (фактические значения изменяются на то же число, что и желаемые, при $r = 1$) [13], рассчитывается по формуле (7):

$$r = \frac{\sum_i (x_i - \bar{x})}{\sqrt{\sum_i (d_i - \bar{d})^2} \sqrt{\sum_i (x_i - \bar{x})^2}}, \quad (7)$$

где x – фактический выход сети; d – желаемый выход.

Результаты обучения сети по обучающей выборке приведены в табл. 1.

Таблица 1

Результаты обучения нейронной сети

Обучение						
Год	Желаемый выход NGAAFM	Фактический выход NGAAFM	Cost	Average Cost	MSE	r
2006	73	73.74	0.000004	–	–	–
2007	157	156.22	0.0000045	–	–	–
2008	258	257.79	0.00000031	–	–	–
2009	324	326.1	0.000033	–	–	–
2010	387	384.93	0.000032	–	–	–
2011	541	541.34	0.00000084	–	–	–
				0.000012	0.000025	0.99

Результаты этапа обучения показали высокую точность аппроксимации входных данных нейронной сетью.

Тестирование представляет собой подачу тестовой выборки на вход уже обученной сети. Тестовая выборка состоит из значений входных параметров и желаемых значений выходных параметров, не использованных в процессе обучения. При этом желаемые значения выходных параметров приводятся лишь для сравнения и никак не используются в процессе тестирования. Таким образом легко оценить точность работы сети. Результаты тестирования сети приведены в табл. 2.

Результаты тестирования сети приведены в табл. 2.

Таблица 2

Результаты тестирования нейронной сети

Тестирование					
Год	Желаемый Выход NGAAFM	Фактический Выход NGAAFM	Cost	Average Cost	MSE
2012	640	630	0.00072	0.00072	0.0014

Тестирование показало, что точность обучения нейронной сети достаточно высока.

В дальнейшей корректировке параметров и настроек сети нет необходимости, т. к. все необходимые регулировки были проведены на этапе экспериментального подбора структуры сети и параметров обучения.

Этап производства отличается от этапа тестирования лишь тем, что на вход уже обученной сети подается производственная выборка, состоящая из значений входных параметров, не использованных в процессе обучения, но без желаемых значений выходных параметров.

Для анализа целесообразности использования нейронных сетей для аппроксимации статистических данных необходимо провести аналогичную аппроксимацию, но традиционным методом, и сравнить полученные результаты с результатами работы нейронной сети. Одним из традиционных методов является метод регрессионного анализа.

При проведении регрессионного анализа необходимо выполнить, по крайней мере, четыре следующих этапа:

- 1) выбрать функцию для построения уравнения регрессии;
- 2) рассчитать коэффициенты (параметры) уравнения регрессии;
- 3) оценить надежность рассчитанных коэффициентов уравнения регрессии;
- 4) проверить качество уравнения регрессии [14].

Модель линейной регрессии является часто используемой и наиболее изученной в эконометрике [15]. Поэтому целесообразно использовать ее для расчета.

Так как для исследования используется выборка за семь лет, с 2006 по 2012 гг., целесообразно для проведения регрессионного анализа использовать лишь измерения с 2006 по 2011 гг. Данные за 2012 год необходимо использовать для проверки точности работы построенной регрессионной модели (уравнения) [16] и ее сравнения с точностью работы примененной нейронной сети.

Средняя ошибка аппроксимации составляет 53,86 % по модулю, что достаточно много, если учесть, что в экономических расчетах допускается погрешность 5-8 % [17].

Полученное расчетное значение, 598, находится в пределах заданной доверительной вероятности 95 %. Фактическое значение указанного параметра за 2012 год составляет 640.

Если сравнить точность аппроксимации уравнения регрессии и нейронной сети, становится очевидным, что точность аппроксимации нейронной сети на порядок выше, чем у построенного уравнения регрессии.

При сравнении результатов тестирования нейронной сети с результатами предсказания с помощью уравнения регрессии видно, что результаты, показанные нейронной сетью, гораздо более близки к желаемому значению, чем результаты, показанные уравнением регрессии.

Таким образом, задача анализа целесообразности применения метода нейронных сетей решена успешно. Сравнение показало, что целесообразно применять метод ИНС для построения краткосрочного прогноза изменения парка ВС АОН России по причине его более высокой точности аппроксимации входных данных и предсказания изменения зависимой переменной, чем у метода регрессионного анализа.

Построение краткосрочного прогноза изменения парка воздушных судов авиации общего назначения России. Для построения краткосрочного прогноза изменения парка воздушных судов АОН России необходимо прежде всего сформировать новую выборку предикторов. Поможет в этом корреляционный анализ. По его результатам были выделены предикторы, оказывающие наибольшее влияние на изменение парка воз-

душных судов АОН России, которые следует использовать для разработки краткосрочного прогноза изменения парка на 2013-2015 гг. К ним относятся следующие предикторы:

- среднедушевые денежные доходы населения;
- покупка товаров и оплата услуг;
- прирост денег на руках у населения;
- источники средств от приватизации государственного и муниципального имущества.

В качестве зависимых переменных используются данные:

- самолетов АОН бизнес-класса иностранного производства, штук (NBJ);
- легких самолетов АОН иностранного производства, штук (NGAA);
- вертолетов АОН иностранного производства с газотурбинными двигателями, штук (NGAHGT);
- вертолетов АОН иностранного производства с поршневыми двигателями, штук (NGAHP).

По результатам экспериментов наиболее высокие характеристики при данной выборке показала сеть нечеткой логики (CANFIS Network, Fuzzy Logic).

Подобранные экспериментально характеристики сети и параметры обучения выглядят следующим образом:

- Learning Rule (правило обучения): Momentum;
- Maximum Epochs (максимальное число эпох обучения): 235.

Остальные настройки идентичны использовавшимся для построения пробного прогноза.

На этапе обучения сети, проведенного с использованием обучающей выборки, были получены следующие экспериментальные данные (табл. 3):

Таблица 3

Результаты обучения нейронной сети по обучающей выборке

	Обучение											
	Желаемый выход				Фактический выход				Cost	Average Cost	MSE	r
	NBJ	NGAA	NGAHGT	NGAHP	NBJ	NGAA	NGAHGT	NGAHP				
2006	14	4	21	34	13,29	3,08	23,1	44,91	0,0013	–	–	-
2007	16	14	38	89	16,87	15,29	35,99	76,72	0,0017	–	–	-
2008	25	31	59	143	24,8	32,49	59,61	142,66	0,000066	–	–	-
2009	27	56	73	168	27,95	53,89	72,27	168,01	0,0007	–	–	-
2010	35	72	90	190	34,16	73,42	90,26	189,59	0,00053	–	–	-
2011	36	146	128	231	36,28	145,37	127,62	232,68	0,000084	–	–	-
2012	38	179	150	273	37,92	179,36	150,52	273,28	0,000014	–	–	-
										0,00064	0,0013	0,99

Судя по полученным на этапе обучения расчетным данным, используемая сеть при выбранных настройках обладает достаточно высокой точностью аппроксимации входных данных.

Этапа тестирования сети в данном расчете нет по причине отсутствия данных об изменении парка ВС АОН России за 2013-2015 гг., таким образом, адекват-

ность прогноза, полученного на этапе производства, можно оценить лишь субъективно, по полученным производственным данным.

Все необходимые корректировки настроек применяемой нейронной сети были завершены на этапе экспериментального подбора структуры сети и параметров обучения.

Результаты производства сети, полученные с использованием производственной выборки, приведены в табл. 4.

Таблица 4

Результаты производства нейронной сети

	Производство			
	Фактический выход			
	NBJ	NGAA	NGAHGT	NGAHP
2013	42,52	195,56	171,06	295,97
2014	45,96	232,79	196,13	336,42
2015	49	270,05	219,17	381,11

Объективно оценить точность результатов, полученных на этапе производства, можно будет лишь при их сравнении с реальными данными, пока недоступными.

Заключение

Проведенное исследование показало, что для эффективного и быстрого формирования выборки предикторов изменения парка воздушных судов авиации общего назначения целесообразно применение двух различных методов, чем обеспечивается всесторонний анализ входных данных. Метод искусственных нейронных сетей показал более высокую точность аппроксимации входных данных за счет своей адаптивности и гибкости, чем метод регрессионного анализа.

Литература

1. Четыргин Е.М. Статистические методы прогнозирования. Изд. 2-е, перераб. и доп. М.: Статистика, 1977. 200 с.
2. Арасланов С. Нетуманные перспективы // Авиация общего назначения. 2010. № 7. С. 4-19.
3. Арасланов С.А., Щербак Ю.В. Перспективы и реальность // Там же. 2012. № 8. С. 6-11.
4. Официальная статистика [Электронный ресурс] // федер. служба государственной статистики: сайт. URL: <https://gks> (дата обращения: 04.07.2013).
5. Indicators [Электронный ресурс] // WorldBank: сайт. URL: <http://data.worldbank.org/indicator/all> (дата обращения: 04.07.2013).
6. Спиридонова О.А. От Росавиации [Электронный ресурс]: письмо ФАВТ от 13 июня 2013 г. URL: <https://www.mtvtcr.php> (дата обращения: 04.07.2013).
7. Цвелева Г.И. Прогнозирование развития АОН СЗ региона: дис. ... канд. техн. наук. М., 2011. 245 с.
8. Этапы решения задач при помощи искусственных нейронных сетей [Электронный ресурс] LiveInternet: сайт. URL: <http://www.liveinternet.ru/users/tsisa/post202199919> (дата обращения: 09.09.2013).

9. Раздел "Fuzzy Network – CANFIS". Демонстрационные материалы (Demos) программы NeuroSolutions 5.
10. Глава "Normalization File". Файл "Помощь" (Help) программы NeuroSolutions 5.
11. Глава "L2 Criterion". Файл "Помощь" (Help) программы NeuroSolutions 5.
12. Глава "Performance measures". Файл "Помощь" (Help) программы NeuroSolutions 5.
13. Глава "Correlation Coefficient". Файл "Помощь" (Help) программы NeuroSolutions 5.
14. Регрессионный анализ [Электронный ресурс] // sde.ru: сайт. URL: <http://www.sde.ru/files/t/Kazakov/Book/section3.pdf> (дата обращения: 02.09.2013).
15. Линейная регрессия [Электронный ресурс] // Wikipedia: сайт. URL: <http://ru.wikipedia.org/wiki> (дата обращения: 04.09.2013).
16. Проверка адекватности регрессионной модели [Электронный ресурс] // helpstat: сайт. URL: <http://helpstat.ru/2012/01/proverka-adekvisionnoj-modeli> (дата обращения: 05.09.2013).
17. Савицкая Г.В. Анализ хозяйственной деятельности предприятия [Электронный ресурс] // bibliotekar: сайт. URL: <http://www.bibliotekar.ru> (дата обращения: 03.09.2013).

References

1. Chetyrgin E.M. Statistical methods of forecasting. M.: Statistika, 1977. 200 s.
2. Araslanov S.A. Non-clouded prospects // Aviatsiya obshchego naznacheniya. 2010. №7. S. 4-19.
3. Araslanov S.A., Shcherbak Yu.V. Perspectives and reality // Aviatsiya obshchego naznacheniya. 2012. №8. S. 6-11.
4. Official statistics// Federal State Statistics Service URL: <https://gks.ru> (access date: 04.07.2013).
5. Indicators.URL: <http://data.worldbank.org/indicator/all> (access date: 04.07.2013).
6. Spiridonova O.A. Subject: from FATA. Letter from FATA June 13, 2013, 14:32 Received to mailbox service mail.ru
7. Tsveleva G.I. Prognostication for the general purpose aviation development of the North-west region: dis. ... kand. tekhn. nauk. M. 2011. 245 s.
8. Stages of problem solving using artificial neural networks. URL: <http://www.liveinternet.ru/users/tsisa/post202199919> (access date: 09.09.2013).
9. Fuzzy Network - CANFIS. Demos, NeuroSolutions 5.
10. Normalization File. Help, programs NeuroSolutions 5.
11. L2 Criterion. Help, programs NeuroSolutions 5.
12. Performance measures. Help, programs NeuroSolutions 5.
13. Correlation Coefficient. Help, programs NeuroSolutions 5.
14. Regression analysis //URL: <http://www.sde.ru/files/t/Kazakov/Book/section3.pdf> (access date: 02.09.2013).
15. Linear regression. //URL: http://ru.wikipedia.org/wiki/Linear_regression (access date: 04.09.2013).
16. Regression model adequacy checking. //URL: <http://helpstat.ru/2012/01/proverka-adekvisionnoj-modeli> (access date: 05.09.2013).
17. Savitskaya G.V. The analysis of the enterprise economic activity //URL: <http://www.bibliotekar.ru/deyatelnost-predpriyatiya-2/index.htm> (access date: 03.09.2013).