

МИНИСТЕРСТВО ОБРАЗОВАНИЯ И НАУКИ РФ
ИНСТИТУТ ИНФОРМАЦИОННОГО ОБРАЗОВАНИЯ
РОССИЙСКОЙ АКАДЕМИИ ОБРАЗОВАНИЯ



ВСЕРОССИЙСКАЯ ГРУППА
ТЕОРИИ ИНФОРМАЦИИ ИКЕЕ



ПЕНЗЕНСКИЙ ГОСУДАРСТВЕННЫЙ
УНИВЕРСИТЕТ



ОБЩЕСТВО «ЗНАНИЕ» РОССИИ
ПРИВОЛЖСКИЙ ДОМ ЗНАНИЙ

XV Международная
научно-техническая конференция

**ПРОБЛЕМЫ ИНФОРМАТИКИ
В ОБРАЗОВАНИИ, УПРАВЛЕНИИ,
ЭКОНОМИКЕ И ТЕХНИКЕ**

Сборник статей

Пenza 2015

Тархов Дмитрий Альбертович
Санкт-Петербургский
государственный политехнический
университет Петра Великого,
г. Санкт-Петербург, Россия
E-mail: dtarhov@gmail.com

Радченко Дарья Сергеевна
Санкт-Петербургский
государственный политехнический
университет Петра Великого,
г. Санкт-Петербург, Россия
E-mail: darya.darya.eschenko@mail.ru

Tarikhov D.A.
Peter the Great Saint-Petersburg
Polytechnical University,
Saint-Petersburg, Russia

Radchenko D.S.
Peter the Great Saint-Petersburg
Polytechnical University,
Saint-Petersburg, Russia

УДК 314.7.044

ОБРАТНАЯ ЗАДАЧА МОДЕЛИРОВАНИЯ МИГРАЦИОННЫХ ПОТОКОВ

Д.А. Тархов, И.К. Шамалин, Д.О. Шаханов

THE REVERSED PROBLEM OF MIGRATION STREAMS MODELING

D.A. Tarikhov, I.K. Shar'shin, D.O. Shahanov

Аннотация. Рассмотрены методы решения обратной задачи моделирования миграционных потоков. Обосновано использование нейронных сетей для построения указанных моделей.

Ключевые слова: социодинамика, миграция, динамические системы, нейронные сети.

Abstract. This article discusses methods of solution the reversed problem of migration streams modeling. The article proves the use of neural networks for construction of shown models.

Keywords: sociodynamics, migration, dynamic systems, neural networks.

В [1] рассмотрены модели миграционных потоков в виде динамических систем

$$\begin{cases} \frac{dx}{dt} = \mu(k_1x + k_2y) - x \operatorname{ch}(k_3x + k_4y) \\ \frac{dy}{dt} = x\operatorname{sh}(k_1x + k_2y) - y \operatorname{ch}(k_3x + k_4y) \end{cases} \quad (1)$$

и линеаризованная система в окрестности нулевого положения равновесия

$$\begin{cases} \frac{dx}{dt} = (k - 1)x + k_1 y \\ \frac{dy}{dt} = k_1 x + (k - 1)y \end{cases} \quad (2)$$

Для построения прогноза миграционной динамики в соответствии с моделями (1)–(2) необходимо определить коэффициенты данных моделей k, k_1, k_2 по имеющимся данным. Для этого можно предложить следующие подходы.

Во-первых, можно решить аналитическую систему (2) и определить коэффициенты по изначальному соответствию решения и данных. Недостаток такого подхода является невозможность распространения на нелинейную систему (1) и необходимость получать аналитическое решение заново при распространении на модели более высокого порядка.

Во-вторых, можно провести дискретизацию системы (2)

$$\begin{cases} \frac{x(t_{n+1}) - x(t_n)}{\Delta t} = (k - 1)x(t_n) + k_1 y(t_n) \\ \frac{y(t_{n+1}) - y(t_n)}{\Delta t} = k_1 x(t_n) + (k - 1)y(t_n) \end{cases} \quad (3)$$

и определить ее коэффициенты по формулам для двумерной линейной регрессии. При этом проблема распространения на более высокие порядки решается очевидным образом, но в случае нелинейной системы (1) без преодоления существенных трудностей такой подход не распространяется.

В-третьих, можно численно решить систему для достаточно большого набора параметров k, k_1, k_2 , далее обучить нейронные сети [2, 3] для определения каждого из них по данным, после этого вычисление коэффициентов модели по наблюдениям сводится просто к подстановке данных в нейронную сеть. При этом применимость метода не зависит от того, какая модель рассматривается – линейная (1) или нелинейная (2).

Результаты вычислений

Для значений коэффициентов $k=1.2; k_1=-0.5; k_2=0.5$ получились следующие результаты.

Второй метод (такимбай разрезом).

При количестве входных точек, равном двум, мы получаем скользящее расхождение расчетной модели с теоретической, однако форма графика не исказена. С увеличением количества точек до 10 в окрестности начала координат (для интервала времени от 0 до 1) имеем нелинейное приближение, но погрешность все еще велика. Далее, увеличивая количество точек до 100, мы достигаем отличной точности, графики функций теоретической и расчетной модели практически совпадают. Однако, если увеличить пе-

рода времени, для которого мы составили модель в 10 раз, то погрешность становится очень большой, это говорит о том, что по 100 точкам не получается хорошо прогнозировать тенденцию миграции на достаточно большой промежуток времени (рассматриваясь период прогноза в 5 раз больше, чем период времени, для которого спроектирован) и, чтобы достичь приемлемого приближения, необходимо увеличение количества точек. Увеличив до 1000 , оставляя интервал времени прежний. В этом случае точность достаточно высока. Но в практических задачах зачастую бывает трудно получить такое большое количество входных данных.

Модель нейронного моделирования. Сети обучались для набора из 300 точек с параметрами из области $k \in [0,2]$; $t_0 \in [-1,0]$; $k_0 \in [0,1]$; $k_1 \in [0,2]$; $k_2 \in [-1,0]$; $k_3 \in [0,1]$.

Для начала выберем количество нейронов, равное пяти. Модель полученная с использованием такой сети по трем точкам из интервала $[0, 1]$ (момент времени 0, 0,5 и 1) отражает основную тенденцию, однако существует значительная погрешность и искасание скорости изменения количества человек в регионах. Однако, если использовать уравнение (1), то есть линейную модель, точность значительно лучше и искасение скорости несущественно. Это является преимуществом нейронных сетей: линейная модель, которая является более точной, аппроксимируется лучше. При увеличении числа нейронов до 15 достигается хорошая точность, особенно в окрестности начала координат. При увеличении размера нейронной сети до 25-ти нейронов, при работе с линейной моделью, результат совпадает с результатом метода линейной регрессии при ста точках. При работе с линейной моделью, мы достигаем при таком периоде времени практически полного совпадения графиков. Кроме того, даже при увеличении периода времени в 10 раз, мы излучаем отличное приближение, причем на всех участках.

Исходя из проведенных вычислительных экспериментов, можно сделать вывод, что нейронные сети при количестве нейронов большое или равном 25 хорошо аппроксимируют модель. Для того чтобы достичь той же точности с использованием линейной регрессии, необходимо большое количество входных данных. Кроме того, такой метод не подходит для случая линейной модели, которая является более точной, так как линейная при увеличении периода времени дает недостаточно точные данные. Применение нейронных сетей можно рекомендовать для решения обратной задачи моделирования миграционных потоков и для решения других подобных задач социолингвистического прогнозирования.

Сборник подготавливается по результатам исследования, выполненного при финансовой поддержке гранта Российской Национальной Фонда (проект 14-38-00099) «Программно-целевое управление комплексным развитием Академической линии РГУ (Санкт-Петербургский политехнический университет Петра Великого).

Библиографический список

1. Вайдин В. Социодинамика: системный подход к математическому моделированию в социальных науках / пер с англ. – М.: Едиториал УРСС, 2005. – 480с.
2. Васильев А.Н., Тархов Д.А. Нейросетевое моделирование. Принципы. Алгоритмы. Применения. – СПб.: Изд-во Политехн. ун-та, 2009. – 528 с.
3. Тархов Д.А. Нейросетевые модели и алгоритмы. – М.: Радиотехника, 2014. – 352 с.

Тархов Дмитрий Альбертович
Санкт-Петербургский
государственный политехнический
университет Петра Великого,
г. Санкт-Петербург, Россия
E-mail: darkhov@gmail.com

Шаньшин Иван Константинович
Санкт-Петербургский
государственный политехнический
университет Петра Великого,
г. Санкт-Петербург, Россия
E-mail: ivan.fizik92@yandex.ru

Шаханов Дмитрий Олегович
Санкт-Петербургский
государственный политехнический
университет Петра Великого,
г. Санкт-Петербург, Россия
E-mail: trupaveman@gmail.com

Tarkhov D.A.
Peter the Great Saint-Petersburg
Polytechnical University,
Saint-Petersburg, Russia

Shan'shin I.K.
Peter the Great Saint-Petersburg
Polytechnical University,
Saint-Petersburg, Russia

Shahanov D.O.
Peter the Great Saint-Petersburg
Polytechnical University,
Saint-Petersburg, Russia