

## СРАВНИТЕЛЬНЫЙ АНАЛИЗ ПРОГНОЗНЫХ СВОЙСТВ МОДЕЛЕЙ РОССИЙСКОЙ ИНФЛЯЦИИ

Т. Горшкова, н.с., РАНХиГС  
Е. Синельникова, доцент, ЭФ РАНХиГС

### Введение

Инфляция является одним из наиболее актуальных макроэкономических показателей. Она оказывает влияние на поведение всех экономических агентов и может приводить к искажению равновесия на всех рынках. По этой причине при принятии решений и частному, и государственному секторам необходимо иметь представление о будущем поведении общего уровня цен.

На сегодняшний день существует множество моделей и подходов, хорошо зарекомендовавших себя для решения задачи краткосрочного прогнозирования инфляции в странах Западной Европы и США. Наряду с традиционными моделями используются новые методы прогнозирования. В частности, в странах Западной Европы для прогнозирования инфляции используется метод нейронных сетей (McNelis, McAdam, 2004, Stasinakis, Charalampos, 2013).

Данная статья посвящена исследованию прогнозных свойств различных модификаций нейронных сетей на российских данных с целью выбора наиболее адекватной модели прогнозирования инфляции.

В качестве меры уровня инфляции использовался индекс потребительских цен (CPI). Для измерения качества прогноза была рассчитана средняя абсолютная ошибка прогноза, выраженная в процентах (MAPE).

### 1. Описание исходных данных


Мы использовали ежемесячные данные российских макроэкономических показателей: индекса потребительских цен, уровня безработицы, валютного курса. Данные по индексу потребительских цен и по уровню безработицы с января 2000 г. по декабрь 2014 г. были взяты с сайта Федеральной службы государственной статистики ([www.gks.ru](http://www.gks.ru)), данные по валютному курсу – с сайта ЦБ.

На *рис. 1* приведен график показателя российской инфляции (в процентах относительно предыдущего месяца).

По аналогии с работой (Choudhary, Haider, 2012) были построены две нейронные и две квази-нейронные сети, в которых в качестве входных параметров использовались только текущие и запаздывающие значения инфляции за два периода.


### 2. Одномерные нейронные сети

Искусственная нейронная сеть (ИНС) – математическая модель, построенная по принципу организации и функционирования биологических нейронных сетей (сетей нервных клеток).



Источник: авторский график.

Рис. 1. Инфляции в России с января 2000 г. по декабрь 2014 г., в % по отношению к предыдущему месяцу



Источник: авторская схема.

Рис. 2. Структура стандартной нейронной сети

Нейронные сети возникли в области исследований искусственного интеллекта, связанных с попытками воспроизвести способность биологических нервных систем обучаться и исправлять ошибки (Patterson, 1996).

При моделировании одного искусственного нейрона предполагается, что через несколько входных каналов нейрон получает входные сигналы (исходные данные из природы или от других нейронов нейронной сети). Взвешенная сумма входных сигналов обрабатывается с помощью функции активации (обычно это математическая функция, определенным образом преобразующая имеющуюся информацию) и распределяется по нейронам первого скрытого слоя. Информация, полученная на первом скрытом слое, снова взвешивается, обрабатывается активационной функцией и передается в нейроны следующего слоя. После того как вся сеть обработает информацию, выходные значения элементов выходного слоя принимаются за выход всей сети в целом.

Например, для моделирования инфляционных процессов с помощью нейронной сети можно использовать структуру сети, представленную на рис. 2.

Во входном слое имеются объясняющие переменные  $x_1, \dots, x_N$ , которые будут использоваться для моделирования инфляции. В данной статье в качестве таких переменных использовались запаздывающие значения инфляции, а также данные по курсу и безработице. Эти переменные умножаются на некие весовые коэффициенты  $a_1, \dots, a_N$ . Изначально коэффициенты выбираются случайным образом. При переходе на скрытый слой переменные, умноженные на коэффициенты, обрабатываются активационной функцией. Существует несколько стандартных активационных функций, используемых при работе с нейронными сетями, в том числе линейная, логистическая и функция гиперболического тангенса.

В данной статье используется функция гиперболического тангенса  $\tanh(x) = \frac{e^{2x} - 1}{e^{2x} + 1}$ . Преимущество данной функции заключается в том, что благодаря симметричному распределению относительно нуля функция обеспечивает более быструю сходимость процесса обучения сети. Таким образом, в нейроны первого скрытого слоя поступают объясняющие переменные  $x_1, \dots, x_N$ , преобразованные в следующий вид:

$$a'_1 * \tanh(a_1 x_1 + a_N x_N) = a'_1 \frac{e^{2(a_1 x_1 + a_N x_N)} - 1}{e^{2(a_1 x_1 + a_N x_N)} + 1}, \dots, a'_M \frac{e^{2(a_1 x_1 + a_N x_N)} - 1}{e^{2(a_1 x_1 + a_N x_N)} + 1}.$$

Количество нейронов в скрытом слое может быть не равно количеству объясняющих переменных ( $M \neq N$ ). Здесь коэффициенты  $a'_1, a'_M$  не равны коэффициентам  $a_1, a_N$ , но все еще не обладают смысловой нагрузкой.

Если в сети несколько скрытых слоев, то после первого скрытого слоя информация вновь обрабатывается активационной функцией, которая может отличаться от функции, используемой в первом случае. На следующем скрытом слое  $M$  весовых коэффициентов  $a'$  преобразуются в  $K$  новых коэффициентов  $a''$ . Например, если на втором скрытом слое также используется активационная функция гиперболического тангенса, то

$$a''_1 = \tanh[a'_1 * \tanh(a_1 x_1 + a_N x_N) + a'_M * \tanh(a_1 x_1 + a_N x_N)]$$

Наконец, на выходе нейронная сеть дает одно число для каждого периода, в котором используется вся преобразованная информация за соответствующий период:  $a * f(x_1, \dots, x_N)$ , где  $a$  – некий весовой коэффициент.

Если у исследователя есть информация по 25 наблюдениям, то на выходе нейронная сеть выдаст 25 значений, в которых использовались объясняющие переменные за соответствующий период. Этот конечный результат (25 выходных значений – по одному для каждого момента времени) принимается за прогнозируемое значение инфляции, каждое значение сравнивается с фактическим значением инфляции в текущем периоде, и высчитывается ошибка прогноза.

На основе этой ошибки прогноза происходит следующая итерация нейронной сети (обычно итерации называются «эпохами»): изначальные весовые коэффициенты входного слоя  $a_1, \dots, a_N$  изменяются таким образом, чтобы на выходе получилась меньшая ошибка прогноза. Затем объясняющие переменные, умноженные на новые коэффициенты для второй эпохи, снова обрабатываются теми же активационными функциями, что и в первой эпохе, а на выходе получается новое значение  $a^2 * f(x_1, \dots, x_N)$  и рассчитывается ошибка прогноза. В следующей эпохе начальные коэффициенты снова изменяются с целью уменьшения ошибки прогноза.

Целью нейронной сети является получение таких прогнозных значений в каждом периоде, для которых средняя ошибка прогноза была бы минимальной. Описанный процесс обучения сети прекращается, когда пройдено определенное количество эпох, или когда ошибка прогноза достигнет некоторого определенного уровня, или когда ошибка прогноза перестанет повторяться. При моделировании макроэкономических показателей требуется, чтобы сеть прошла в среднем 3000 эпох.

При таком подходе существует риск переобучения сети, когда подобранные веса будут точно моделировать значения на обучающей подвыборке, но не смогут обобщить результат на новые наблюдения. Однако если сеть обучена хорошо, она приобретает способность моделировать неизвестную для исследователя функцию, связывающую значения входных и выходных переменных, и впоследствии такую сеть можно использовать для прогнозирования вне выборки.

Наряду с основным преимуществом, которое заключается в нелинейности, нейронная сеть обладает существенным недостатком – сложностью в интерпретации. С ее помощью можно получить достаточно точный прогноз (чаще всего точность прогноза превосходит точность линейных моделей), но объяснить, почему был получен такой прогноз, практически невозможно в связи с тем, что неизвестен вид зависимости между объясняемой и объясняющими переменными.

В данной статье было использовано несколько типов нейронных сетей. Первая модель (гибридная) представляет собой нейронную сеть, в которой используется стандартный алгоритм обратного распространения ошибок:

$$\hat{\pi}_{t+j} = \sum_{k=1}^n \theta_k \tanh(w_k x_{t-k} + b_k),$$

где  $\hat{\pi}_{t+j}$  – прогноз, основанный на нейронной сети, на  $j$  месяцев вперед,  $x_{t-k}$  – вектор объясняющих переменных,  $\theta$  – веса скрытых слоев,  $w_k$  – веса входных данных,  $b_k$  – пороговое значение.

Вторая модель (динамическая) учитывает внутренний отклик системы (в нейроны скрытого слоя на шаге  $t+1$  включаются значения сигналов входного слоя на шаге  $t+1$  и значения сигнала выходного слоя на шаге  $t$ ). Тогда функция для выхода принимает следующий вид:

$$\hat{\pi}_{t+j} = F(\beta_0 + \sum_{j=1}^K G(\pi \zeta_{ij} + \hat{\pi}_{t+j-1} \delta_j) \beta_j),$$

где  $\pi$  – вектор входных параметров,  $F$  и  $G$  – активационные функции для нейронов выходного и скрытого слоев соответственно,  $\beta_0$  – пороговое значение,  $\beta_j$  – веса, связывающие  $j$ -й элемент скрытого слоя и выходной слой,  $\zeta_{ij}$  – веса, связывающие  $i$ -й элемент входного слоя с

$j$ -м элементом скрытого слоя,  $\delta_j$  – веса, связывающие выход сети с  $j$ -м элементом скрытого слоя.

Графическое представление такой сети приведено на *рис. 3*.

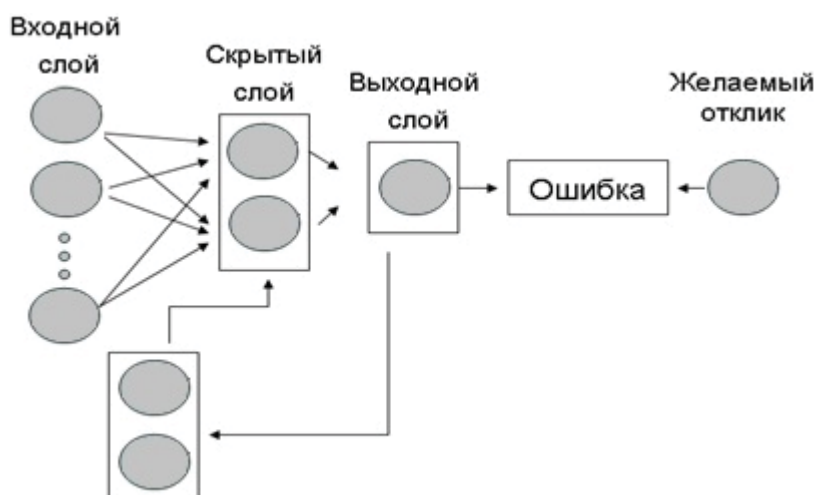
Третья модель (среднее) является средним прогнозов гибридной и динамической моделей. Четвертая ИНС (минимальное расстояние) использует критерий минимального расстояния, в котором выбирается либо гибридная, либо динамическая модель в зависимости от того, какая из них ближе к среднему прогнозу в данной точке.

Для построения этих моделей данные были нормированы на максимальное значение. При данном способе нормализации максимальное историческое значение инфляции (январь 2002 г. – 103,9) принимается за 1, остальные данные берутся в отношении к максимальному. В качестве активационной функции использовалась функция гиперболического тангенса

$\tanh(x) = \frac{e^{2x} - 1}{e^{2x} + 1}$ . Во входном слое используются значения инфляции за два предыдущих периода. При использовании месячных данных рекомендуется использовать 12 нейронов в скрытом слое. Архитектура сетей имеет следующий вид: 2–12–1<sup>2</sup>.


В качестве обучающей выборки был использован ряд инфляции с января 2000 г. по октябрь 2013 г. Оставшиеся значения составили контрольную выборку.

Результаты прогнозирования представлены на *рис. 4*.



Источник: авторская схема.

Рис. 3. Рекуррентная сеть с внутренним откликом выходного слоя<sup>1</sup>



Источник: расчеты авторов.

Рис. 4. Сравнение результатов нейронных сетей с реальными данными

<sup>1</sup> Подробный алгоритм построения динамической нейронной сети описан в работе (Scuse et al., 1999).

<sup>2</sup> При описании архитектуры нейронной сети принята следующая форма записи:  $k - l_1 - l_2 - \dots - l_p - n$ , где  $k$  – количество объясняющих переменных во входном слое (в нашем случае 2),  $l_i$  – количество нейронов в  $i$ -м скрытом слое (12 нейронов в 1 скрытом слое),  $n$  – количество спрогнозированных переменных в выходном слое (1).

Значения ошибок прогноза, на основе которых будет выбираться наилучшая модель, представлены в *табл. 1*.

Таблица 1

ОШИБКА ПРОГНОЗА, ПОЛУЧЕННОГО С ПОМОЩЬЮ НЕЙРОННЫХ СЕТЕЙ (%)

МАРЕ	Гибридная	Динамическая	Среднее	Минимальное расстояние
Обучающая выборка (январь 2000 – октябрь 2013)	39,53	48,05	43,21	56,04
Контрольная выборка (ноябрь 2013 – декабрь 2014)	31,14	39,29	35,22	40,39

Источник: расчеты авторов.

Среди приведенных моделей наименьшей ошибкой прогноза обладает гибридная модель. Точность прогнозов, полученных с помощью одномерных нейронных сетей, не превышает 70% (максимальная точность прогноза – 68,86% – получается с помощью гибридной модели на контрольной выборке). Однако полученные результаты в целом не противоречат результатам исследований для стран – членов ОЭСР (Choudhary, Haider, 2012).

### 3. Многомерная нейронная сеть

С помощью многослойной нейронной сети с одним скрытым слоем была оценена зависимость инфляции от безработицы и валютного курса. На месячных и квартальных данных, стандартизованных на максимальное значение, были исследованы несколько моделей с разным количеством нейронов в скрытом слое и разными объясняющими переменными.

Сначала были исследованы месячные данные. Наилучший результат дала нейронная сеть с архитектурой 2–6–1. В качестве входов использовались значения уровня безработицы и курса валют, на выходе были получены прогнозные значения ряда инфляции. В связи с отсутствием более ранних данных модель оценивалась на интервале с января 2003 г. по декабрь 2013 г. В качестве контрольной выборки использовались квартальные значения инфляции за 2014 г.


Сравнение ряда реальных значений и значений, спрогнозированных по модели, представлено на *рис. 5*.

По *рис. 5* видно, что спрогнозированные значения обладают меньшей дисперсией, чем реальные. Ошибки прогноза по обучающей и контрольной выборкам приведены в *подпункте а) табл. 2*.

На квартальных данных, не очищенных от сезонности, наилучший результат показала нейронная сеть с архитектурой 2–3–1. На выходе был получен прогноз для ряда инфляции, очищенного от сезонности.

Графики реального и спрогнозированного рядов практически совпадают, однако на контрольной выборке (2014 г.) дисперсия спрогнозированного ряда меньше, как и в случае месячных рядов.

Ошибки прогноза по обучающей и контрольной выборкам приведены в *подпункте б) табл. 2*.



Источник: расчеты авторов.

Рис. 5. Сравнение ряда реальных значений и значений, спрогнозированных по модели (более волатильный ряд – реальные данные, менее волатильный ряд – спрогнозированные значения)

Таблица 2

## ОШИБКИ ПРОГНОЗА МНОГОМЕРНОЙ НЕЙРОННОЙ СЕТИ

	МАРЕ (%)
а) Обучающая выборка (янв. 2003 – дек. 2013)	23,2
а) Контрольная выборка (янв. 2014 – дек. 2014)	24,33
б) Обучающая выборка (I кв. 2003 – IV кв. 2013)	7,29
б) Контрольная выборка (I кв. 2014 – IV кв. 2014)	9,14

Источник: расчеты авторов.

Попытки включить в нейронные сети запаздывающие значения инфляции и значения выпуска привели к росту ошибок прогноза.

#### 4. Заключение

Структурная нейронная сеть, оценивающая зависимость инфляции от безработицы и валютного курса на квартальных данных, обладает наименьшей ошибкой прогноза. Некоторые исследователи (см., например, Салицкий (2010); Пономарев, Трунин, Улюкаев, (2014); Пономарев (2015)) отмечают, что в России наблюдается умеренная зависимость инфляции от валютного курса, связанная с эффектом переноса курса в цены. Оценки эффекта переноса в литературе показывают, что Россия постепенно приближается к западным странам с низким эффектом переноса. Эти выводы согласуются с результатами, полученными в данной работе. По нейронной сети, построенной на месячных данных, получается большая ошибка прогноза (24%), что может объясняться сильной волатильностью обменного курса в 2014 г. Нейронные сети, учитывающие только прошлые значения инфляции, обладают наименьшей точностью прогноза. Ошибки прогноза по всем рассмотренным моделям приведены в *табл. 3*.

Таблица 3

## СРАВНЕНИЕ РАССМОТРЕННЫХ МОДЕЛЕЙ

Модель	МАРЕ	
	на обучающей выборке (%)	на контрольной выборке (%)
Гибридная нейронная сеть	39,53	31,14
Динамическая нейронная сеть	48,05	39,29
Нейронная сеть, среднее	43,21	35,22
Нейронная сеть, минимальное расстояние	56,04	40,39
Нейронная сеть, квартальные данные	7,29	9,59
Нейронная сеть, месячные данные	23,2	24,33

Источник: расчеты авторов

Таким образом, для прогнозирования инфляции на российских данных мы рекомендуем использовать нейронные сети с учетом обменного курса и безработицы.

Для повышения точности прогноза одномерных моделей при прогнозировании гибридной и динамической нейронной сетью в качестве обучающей выборки использовались значения инфляции за 2000–2015 гг. Прогноз на первые три квартала 2016 г. приведен в *табл. 4*.

Таблица 4

## ПРОГНОЗ НА ЯНВАРЬ–СЕНТЯБРЬ 2016 Г. ПО ОДНОМЕРНЫМ МОДЕЛЯМ

Период	Инфляция по гибридной нейронной сети, %	Инфляция по динамической нейронной сети	Инфляция по усредненной нейронной сети, %	Инфляция по сети минимального расстояния, %	Фактическая инфляция (месяц, %)
Январь 2016	1,03 (7%)	0,99 (3%)	1,01 (5%)	0,99 (3%)	0,96
Февраль 2016	0,82 (30%)	0,76 (21%)	0,79 (25%)	0,76 (21%)	0,63
Март 2016	0,63 (37%)	0,65 (41%)	0,64 (39%)	0,63 (37%)	0,46
Апрель 2016	0,34 (23%)	0,28 (36%)	0,31 (30%)	0,28 (36%)	0,44
Май 2016	0,48 (17%)	0,48 (17%)	0,48 (17%)	0,48 (17%)	0,41

Таблица 4, окончание

Период	Инфляция по гибридной нейронной сети, %	Инфляция по динамической нейронной сети	Инфляция по усредненной нейронной сети, %	Инфляция по сети минимального расстояния, %	Фактическая инфляция (месяц, %)
Июнь 2016	0,97 (143%)	1,01 (148%)	0,99 (148%)	0,97 (143%)	0,4
Июль 2016	0,64	0,64	0,64	0,64	
Август 2016	0,72	0,64	0,69	0,64	
Сентябрь 2016	0,61	0,37	0,49	0,37	
МАРЕ	43%	45%	44%	43%	

Источник: расчеты авторов.

Месячный и квартальный прогнозы на год с июля 2015 г. по октябрь 2016 г., сделанные с помощью моделей с учетом валютного курса и уровня безработицы, приведены в табл. 5.

В качестве базового прогноза, с которым сравнивались результаты нейронных сетей, использовался «наивный» AR(1) прогноз для данных, не очищенных от сезонности, и «наивный» AR(1) для данных, очищенных от сезонности.

Таблица 5

ПРОГНОЗ НА 2015–2016 ГГ. ПО СТРУКТУРНЫМ МОДЕЛЯМ

Период	Инфляция по модели структурной нейронной сети (месяц, %)	Инфляция по «наивной» модели (месяц, %)	Инфляция по «наивной» модели (месяц, %), очищенной от сезонности	Инфляция по структурной нейронной сети (квартал, %)	Инфляция по «наивной» модели (квартал, %)	Инфляция по «наивной» модели (квартал, %), очищенной от сезонности	Фактическая инфляция (месяц, %)	Фактическая инфляция (квартал, %)
Июль 2015	0,45 (44%)	0,46 (43%)	0,27 (66%)				0,8	
Август 2015	0,87 (149%)	0,63 (80%)	0,39 (11%)	1,97 (14%)	1,83 (6%)	1,14 (34%)	0,35	1,73
Сентябрь 2015	0,64 (12%)	0,69 (21%)	0,48 (16%)				0,57	
Октябрь 2015	0,65 (12%)	0,69 (7%)	0,92 (24%)				0,74	
Нояб. 2015	0,8 (7%)	0,76 (1%)	0,87 (16%)	2,28 (1%)	2,49 (8%)	1,77 (23%)	0,75	2,3
Дек. 2015	0,82 (6%)	0,81 (5%)	0,78 (1%)				0,77	
Янв. 2016	0,75 (22%)	0,83 (14%)	0,54 (44%)				0,96	
Фев. 2016	0,81 (29%)	0,85 (35%)	0,38 (40%)	2,16 (5%)	2,7 (31%)	2,05 (0%)	0,63	2,06
Март 2016	0,59 (28%)	0,86 (87%)	0,43 (7%)				0,46	
Апр. 2016	0,29 (34%)	0,87 (98%)	0,5 (14%)				0,44	
Май 2016	0,54 (32%)	0,87 (112%)	0,51 (24%)	1,45 (15%)	2,63 (109%)	2,18 (73%)	0,41	1,26
Июнь 2016	0,61 (53%)	0,87 (118%)	0,61 (53%)				0,4	
Июль 2016	0,59	0,87	0,72					
Авг. 2016	0,64	0,88	0,8	1,84	2,65	2,36		
Сент. 2016	0,6	0,88	0,82					
МАРЕ	36%	52%	26%	9%	38%	33%		

Источник: расчеты авторов.

Из таблицы выше видно, что в течение трех кварталов каждая модель оказалась наиболее точной. В III кв. 2015 г. наиболее точные результаты дала «наивная» AR(1) модель, в IV кв. 2015 г. и II кв. 2016 г. – нейронная сеть, в I кв. 2016 г. – AR(1), очищенная от сезонности. В среднем за 12 месяцев отклонения прогнозных значений по нейронной сети от фактической инфляции были минимальными среди всех трех моделей.

Таким образом, для квартальных данных мы приходим к выводу о том, что использование структурных нейронных сетей позволяет получать более точные прогнозы инфляции и поэтому более предпочтительно для целей прогнозирования, чем использование одномерных моделей.

### Список литературы

*Салицкий И.* Перенос обменного курса рубля в цены импорта Российской Федерации // Экономическая политика. 2010. № 6. С. 176–195.

*Пономарев Ю., Трунин П., Улюкаев А.* Эффект переноса динамики обменного курса на цены в России.» // Вопросы экономики. 2014. № 3. С. 21–35.

*Пономарев Ю.Ю.* Эффект переноса динамики обменного курса рубля в цены в российских отраслях промышленности // Экономическая политика. 2015. № 5. С. 53–70.

*Choudhary M. Ali, Haider Adnan,* 2012. “Neural network models for inflation forecasting: an appraisal”, Applied Economics, Taylor and Francis Journals, vol. 44(20), pp. 2631–2635.

*Hu, Gang and Mihir Worah.* 2009. “Why Tips Real Yields moved significantly higher after the Lehman Bankruptcy.” PIMCO, Newport Beach, CA.

*McAdam P., McNelis P.,* 2004. “Forecasting inflation with thick models and neural networks”, Economic Modelling, 22(5), pp. 848–867.

*Phillips A. W.* 1958. “The Relationship between Unemployment and the Rate of Change of Money Wages in the United Kingdom 1861–1957”, *Economica*, pp. 283–299.

*Scuse, D., Moshiri, S., Cameron, N.* 1999. “Static, Dynamic and Hybrid Neural Networks in Forecasting inflation”, *Computational Economics*, 14, pp. 219–235.

*Stasinakis C.* 2013, “Applications of Hybrid Neural Networks and Genetic Programming in Financial Forecasting”, University of Glasgow.

*Stock, J.H., Watson, M.W.* 1999. “Forecasting Inflation”, *Journal of Monetary Economics*, vol. 44, No. 2, pp. 293–335. ●