

# МЕТОДЫ ОБЪЕДИНЕНИЯ ПРОГНОЗОВ

Иванюк В.А.

Финансовый университет при Правительстве РФ,  
Россия, г. Москва, ул. Ленинградский проспект, д.49  
ivaver6@gmail.com

*Аннотация. Целью работы является оценка временных рядов, предсказания будущих изменений цен и определение паттернов движения рыночных показателей. В работе рассмотрены различные методы прогнозирования временных рядов. В следствие этого, объектом разработки являются временные ряды. Показаны преимущества ансамблевого прогнозирования в отличие от частных прогнозов.*

Ключевые слова: временной ряд, объединение прогнозов, моделирование

## Введение

Временной ряд – это упорядоченная по времени последовательность событий. Временные ряды, как правило, возникают в результате измерения какого-либо показателя. Это могут быть показатели природных, экономических и социальных явлений, характеристики технических систем.

Прогноз разрабатывается для интервала времени, называемым временем упреждения. При анализе временных рядов часто основной целью является построение прогнозов. Старые методы постоянно совершенствуются и развиваются, при этом идет разработка новых методов и их гибридизация. В теории прогнозирования остается много пока еще не устраненных проблем, из-за чего обоснован спрос на создание эффективных аналитических прогнозных систем.

При моделировании временного ряда можно выделить две основные составляющие:

- Моделирование неслучайной составляющей;
- Разложение ряда на составляющие и моделирование значений для каждой компоненты в отдельности.

Наблюдаемый временной ряд предполагается состоящим из ненаблюдаемых составляющих, поэтому его можно разложить на независимые составляющие, несущие в себе разную содержательную нагрузку:

- Сезонные колебания. Сезонные компоненты – повторяющиеся по отношению к тенденции явления (пики, подъемы или падения) в данных имеют относительно устойчивые изменения на протяжении изучаемого периода.
- Циклические колебания. Циклические компоненты - повторяющиеся по отношению к тенденции движения вверх и вниз, которые имеют относительно устойчивые изменения на протяжении произвольного периода времени.
- Тренд – это некоторая общая долгосрочная закономерность к изменению значений временного ряда в течение длительного периода времени. Тренд может быть восходящим и нисходящим, или же отсутствовать.

С помощью различных методов прогнозирования можно получить предсказания будущих значений временного ряда [1].

## 1 Объединение прогнозов

Проведем анализ работ современных авторов по теме прогнозирование временных рядов за 2019 - 2021 гг.

В работе Herrera G. P. et al. [7] для прогнозирования используют метод случайного леса и нейронных сетей, которые сравниваются с традиционными эконометрическими моделями. Результаты прогнозирования являются более надежными и могут показать момент перелома.

Авторы Li T. et al. [8] рассматривали гибридную модель, состоящую из SEEMDAN методов, и исследовали ее превосходство над статистическими моделями. Использование гибридной модели заметно повышает качество прогноза.

Автор Di Sanzo S. A. [6] показывает, что модель прогнозирования, включающая в себя одновременно метод долговременной памяти и цепи Маркова, дает более точные результаты по сравнению с результатами достигнутыми выбранными моделями обобщенной авторегрессии и условной гетероскедастичности.

Объединенная модель, состоящая из адаптивной нейро-нечеткой системы вывода (ANFIS), генетического алгоритма (GA) и алгоритма стаи сальп(SSA) была использована авторами Abd Elaziz M., Ewees A. A., Alameer Z. [4] и продемонстрировала, что рассматриваемая гибридная модель

превосходит по точности такие аналоги как оптимизация роя частиц, нейро-нечеткая система вывода (ANFIS), адаптивная нейро-нечеткая система вывода (PSO-ANFIS).

Авторы Zhu J. et al. [11] получили результаты, которые демонстрируют преимущество гибридного подхода над такими моделями как сглаживание Холта, общая регрессионная нейронная сеть, нелинейная авторегрессионная нейронная сеть и т.д.

Авторы Wang M. et al. [10] применяли гибридную модель, состоящую из нейронной сети и методов машинного обучения. Результаты их работы показывают, что объединенная модель превосходит составные с точки зрения точности.

Abdollahi H. [5] на основе эмпирического анализа, пришел к выводу, что применяемая гибридная модель, состоящая из улучшенной полной ансамблевой эмпирической модели разложения (CEEMD), метода опорных векторов (SVM), оптимизации роя частиц (PSO), модели Маркова (MC GARCH), превосходит по точности каждый из частных методов прогнозирования.

При решении задач прогнозирования часто можно столкнуться с ситуацией, когда ни один из применяемых методов не может обеспечить необходимую точность [1]. В таких случаях построение композиции алгоритмов почти гарантированно может увеличить точность прогноза [2-3]. Такой метод является наиболее эффективным, чем применение единственного метода прогнозирования [9].

Общие подходы для построения ансамблевых моделей включают в себя различные конкретные методы. Наиболее распространенными из них являются:

- Бэггинг. Путем усреднения полученных различными методами результатов прогнозирования можно добиться уменьшения дисперсии. Суть метода заключается в том, что изначальный набор данных разбивается на несколько частей, на которых будет проходить обучение используемых алгоритмов. При подведении итогового результата частных методов используется средне-взвешенное значение или усреднение с использованием среднего арифметического значения.
- Бустинг. Основа этого метода заключается в том, что обучение базовых методов проходит последовательно на наборе, который претерпевает изменения подвергаясь результату работы каждого из методов. Благодаря такому механизму действий обеспечиваются результаты, которые можно считать хорошими, даже если в качестве частных методов применяются слабые методы.
- Стэкинг. Принцип этого метода заключается в использовании базовых моделей, сформированных на основе исходного обучающего набора, для получения предсказаний и использование их результатов некоторым обобщающим метаалгоритмом.

Если рассматривать вопрос построения совокупного прогноза, то ключевой задачей считается получение весовых коэффициентов, на основе которых будут учитываться результаты прогнозных методов. В зависимости от применяемого алгоритма нахождения весовых коэффициентов зависит итоговая прогнозная точность. При этом весовые коэффициенты ограничиваются таким образом:

- 1) их сумма должна равняться единице;
- 2) каждый коэффициент лежит в диапазоне от 0 до 1.

При построении модели прогнозирования важнейшим критерием качества модели является ее точность. Очевидно, что модель, обладающая низкой точностью, не может применяться в качестве надежного источника информации. При построении прогноза одной из важнейших задач является правильный выбор метрик точности и правильной интерпретации полученных результатов.

Наиболее используемыми методами оценки точности прогноза является MAPE, MAE и RMSE. MPE — средняя процентная ошибка прогнозирования. Среди минусов такой ошибки значится несимметричность: разное влияние на показатель ошибки оказывают отклонения в плюс и в минус от реального значения. Кроме того, основным недостатком этой ошибки является значительное изменение показателя при применении её к нестабильному временному ряду, где каждый выброс или незначительное колебание существенно изменяют показатели точности. MAPE — средняя абсолютная процентная ошибка прогнозирования. Основные недостатки такие же, как и у MPE – нестабильность. RMSE — среднеквадратичная ошибка прогнозирования. Основные недостатки такие же, как и у предыдущих – нестабильность. MASE — средняя абсолютная масштабированная ошибка прогнозирования. Из достоинств этой ошибки стоит отметить ее симметричность и независимость от величины используемых данных. MAE – средняя абсолютная ошибка. MAE измеряет среднюю величину ошибок в наборе прогнозов без учета их направления. MAD - среднее абсолютное отклонение. Это средняя ошибка по модулю, применяется в случаях, когда ошибку важно измерить в тех же единицах, что и исходный ряд. Проверка адекватности модели осуществляется на основе формальных статистических критериев. Обязательным условием такой проверки является наличие

надежных и достоверных статистических параметров объекта прогнозирования и самой модели. При отсутствии таких оценок проводится сравнение отдельных свойств изучаемого объекта и модели. При этом первоначально должна проверяться истинность реализуемых функций, затем правильность структуры и, наконец, достоверность достигаемых при этом значений параметров. Верификация модели – представляет собой анализ функциональной полноты, точности и достоверности модели, осуществляемый на основе всей доступной информации в тех ситуациях, когда проверку адекватности по каким-либо причинам провести нельзя. Как показывает практика, абсолютное совпадение прогноза и реального процесса происходит крайне редко, в связи с чем задача верификации прогнозной модели остается весьма актуальной.

### 1.1 Классификация методов прогнозирования

Все методы прогнозирования делятся на два вида:

- Интуитивные методы;
- Формализованные методы.

Интуитивные или эвристические методы прогнозирования основаны на опыте и суждении экспертов. Эти методы применяются при слишком простом объекте прогнозирования, либо, когда все взаимосвязи в прогнозируемом процессе учесть невозможно. Интуитивный метод можно разделить на:

- Методы исторических аналогий и прогнозов по образцу;
- Экспертные и коллективные оценки.

Формализованные методы основаны на описании закономерностей в потоках данных и применении в их описании математических формул и делятся на:

- Экономико-статистический метод;
- Метод экстраполяции;
- Моделирования;
- Распознавания образов (нейронные сети);
- Адаптивный.

## 2 Преимущество нейронных сетей

Нейронные сети являются наиболее распространенным методом для прогнозирования временных рядов и часто используются в совокупном прогнозе.

Нейронными сетями называют систему алгоритмов, которая пытается распознать основные взаимосвязи в наборе данных с помощью процесса, имитирующего работу человеческого мозга. Нейронные сети способны подстраиваться под изменяющиеся входные данные, находя наилучший результат. Они хороши в прогнозировании событий, которые зависят от нестабильных факторов. Примером такого события является рыночная стоимость товара. Благодаря прохождению хода редактирования синаптических весов и порогов и происходит обучение нейронных сетей. В соответствии с предусмотренным алгоритмом при каждом повторе процесса обучения сети улучшают свое понимание протекающих процессов. Не существует единого алгоритма обучения, только набор средств, составляющий множества различных алгоритмов обучения, каждый из которых имеет свои преимущества.

Рассмотрим несколько простых классификаций нейронной сети. Один из самых простых типов классификации нейронной сети можно сделать по количеству скрытых слоев:

- Нейронная сеть с одним слоем или же однослойная нейронная сеть. Данная структура взаимодействия нейронов реализована посредством попадания входных данных в первый входной слой и последующей передаче конечного результата в выходной слой.
- Многослойные нейронные сети. Данные нейронные сети имеют промежуточные слои, которые называются скрытые нейронные слои. Их количество определяет сложность нейронной сети.
- Классифицируют нейронную сеть по направлению распространения входного сигнала:
- Однонаправленная нейронная сеть или сеть прямого распространения. Сигнал данной нейронной сети движется в одном направлении, от входного слоя к выходному. В данных нейронных сетях сигнал не может двигаться в обратном направлении. Нейросети с подобным типом распространения сигнала имеют достаточно широкое распространение и являются достаточно популярными при решении таких задач как прогноз, распознавание или кластеризация.
- Рекуррентная нейронная сеть или сеть с обратными связями. Данный тип нейронной сети позволяет двигаться сигналу не только в одном направлении, но и в обратном.

Нейронные сети имеют следующие свойства:

1. Нелинейность. Есть несколько видов нейронных сетей, такие как линейные и нелинейные. Не зависимо от вида нейронной сети, они могут воспроизводить и находить сложные зависимости.
2. Параллельная обработка данных. Эта способность нейронных сетей ускоряет обработку информации при большом количестве межнейронных связей.
3. Обучение на примерах. Один из самых популярных примеров обучения является обучения с учителем. Такой метод обучения использует учебные примеры для изменения синоптических весов.
4. Адаптивность. Одной из главных способностей нейронной сети является ее адаптивность. Она позволяет подстраивать свои синоптические веса в ответ на изменения окружающей среды.
5. Нечувствительность к ошибкам. Из-за достаточно большого количества межнейронных связей сеть становится нечувствительной к ошибкам, которые возникают в отдельных контактах.
6. Способность к обобщению получаемых знаний. Искусственная нейронная сеть обладает определенными чертами искусственного интеллекта. Обученная на некотором множестве примеров, она агрегирует полученную информацию и выдает ожидаемую реакцию на данные, не участвовавшие в процессе тренировки или же обучения нейронной сети.
7. Единообразие анализа и проектирования. Искусственные нейронные сети - это достаточно универсальные механизмы обработки данных. Например, одно проектное решение может быть реализовано в нескольких предметных областях.

Нейронная сеть состоит из множества входных узлов, образующих входной слой. Сигнал распространяется от входного слоя по сети в прямом направлении, двигаясь от слоя к слою. Многослойный персептрон применяется для решения сложных задач.

У многослойного персептрона есть несколько отличительных признаков. Нейронная сеть имеет от одного до нескольких скрытых нейронов. Эти нейроны дают сети обучаться, последовательно извлекая важную информацию, признаки, из сигнала, поданного со входа. Данная нейронная сеть имеет высокую степень связанности, реализуемую с помощью симпатических соединений. Выходной слой сети составляют выходные нейроны. Нейроны, которые не относятся к входным и выходным слоям относятся к скрытым слоям. Когда сигнал поступит с входного слоя он сначала идет в первый скрытый слой, оттуда в следующий и так пока сигнал не дойдет до выходного слоя.

У многослойного персептрона есть несколько типов сигнала:

1. Функциональный сигнал. Данный сигнал для нейронной сети является входным и распространяется в прямом направлении. Данный сигнал проходит через всю нейронную сеть и достигает конца в качестве выходного сигнала. Данный сигнал проходит через каждый нейрон сети и передает от одного нейрона другому сигнал, являющийся результатом вычисления в нейроне определенной функции, полученной от взвешенной суммы входов с уточнением на пороговый элемент, которым в нейронной сети является весовой коэффициент.
2. Сигнал ошибки. Он распространяется в обратном направлении, двигаясь от одного слоя к другому и вычисляется каждым нейроном, через который проходит. Вычисляется на основе функции ошибки.

## **Заключение**

В сетях типа многослойного персептрона очень часто используются сигмоидальные нейроны. Веса и пороговые значения в данных искусственных нейронных сетях являются свободными параметрами. С помощью данной нейронной сети можно смоделировать функцию любой степени сложности.

Многослойный персептрон обладает такими достоинствами как простота в использовании, широкое применение алгоритмов обучения, высокая апробация алгоритмов обучения.

При разработке нейронной сети одним из основных этапов построения является выбор функции активации. Традиционная функция активации сигмоида имеет производную меньше единицы, на все области определения. Это означает, что после нескольких слоев ошибка станет очень быстро приближаться к нулю. Если же наоборот взять функцию активации с неограниченной производной, к примеру такой как гиперболический тангенс, то произойдет очень быстрое увеличение ошибки, что не очень хорошо, так как ведет к неустойчивости обучения.

Таким образом, рассмотрены основные преимущества использования нейронной сети в задачах прогнозирования. А также описаны основные подходы к объединению прогнозов для увеличения точности прогнозирования.

## Литература

1. *Иванюк В. А., Арутюнов А. Л., Цвиркун А. Д.* Разработка инструментальных средств прогнозирования в социально-экономических системах //Препринт доклада.-ИПУ РАН. – 2012. – С. 43.
2. *Иванюк В. А., Цвиркун А. Д.* Разработка многофакторной системы прогнозирования на основе имитационно-оптимизационного подхода //Вестник Новосибирского государственного университета. Серия: Информационные технологии. – 2012. – Т. 10. – №. 1.
3. *Иванюк В. А., Цвиркун А. Д., Попов В. Ю.* Классические подходы к анализу и прогнозированию риска //Управление развитием крупномасштабных систем MISD'2016, под общей редакцией С.Н.Васильева, А.Д.Цвиркуна, – 2016. – С. 286-288.
4. *Abd Elaziz M., Ewees A. A., Alameer Z.* Improving adaptive neuro-fuzzy inference system based on a modified salp swarm algorithm using genetic algorithm to forecast crude oil price //Natural Resources Research. – 2020. – Т. 29. – №. 4. – С. 2671-2686
5. *Abdollahi H.* A novel hybrid model for forecasting crude oil price based on time series decomposition //Applied Energy. – 2020. – Т. 267. – С. 115035
6. *Di Sanzo S.* A Markov switching long memory model of crude oil price return volatility //Energy Economics. – 2018. – Т. 74. – С. 351-359
7. *Herrera G. P. et al.* Long-term forecast of energy commodities price using machine learning //Energy. – 2019. – Т. 179. – С. 214-221
8. *Li T. et al.* Forecasting daily crude oil prices using improved CEEMDAN and ridge regression-based predictors //Energies. – 2019. – Т. 12. – №. 19. – С. 3603
9. *Makridakis S., Winkler R. L.* Averages of forecasts: Some empirical results //Management science. – 1983. – Т. 29. – №. 9. – С. 987-996.
10. *Wang M. et al.* A novel hybrid method of forecasting crude oil prices using complex network science and artificial intelligence algorithms //Applied energy. – 2018. – Т. 220. – С. 480-495
11. *Zhu J. et al.* A novel decomposition-ensemble approach to crude oil price forecasting with evolution clustering and combined model //International Journal of Machine Learning and Cybernetics. – 2019. – Т. 10. – №. 12. – С. 3349-3362