

**Федеральное государственное бюджетное образовательное
учреждение высшего образования
«РОССИЙСКАЯ АКАДЕМИЯ НАРОДНОГО ХОЗЯЙСТВА
И ГОСУДАРСТВЕННОЙ СЛУЖБЫ
ПРИ ПРЕЗИДЕНТЕ РОССИЙСКОЙ ФЕДЕРАЦИИ»**

Каукин А.С., Косарев В.С.

**Идентификация и прогнозирование фаз
российского экономического цикла с учетом отраслевой
структуры экономики при помощи искусственных
нейронных сетей**

Москва 2020

Аннотация. В работе представлен метод условного прогнозирования экономического цикла с учетом отраслевой динамики. Прогнозная модель включает в себя нейросетевой автокодировщик и адаптированную глубокую сверточную сеть архитектуры «WaveNet». Первый функциональный блок модели предназначен для снижения размерности набора объясняющих факторов. Второй блок – для прогноза фазы экономического цикла исследуемой отрасли: нейронная сеть, принимая на вход главные компоненты объясняющих факторов, строит прогноз вероятности нахождения в рецессии. Для перехода к прогнозу агрегированного экономического цикла была применена концепция диффузного индекса. Предложенная модель может использоваться, как самостоятельный, так и вспомогательный метод оценивания темпов роста индекса промышленного производства наряду с динамическими факторными моделями.

Abstract. The paper presents a method for conditional forecasting of the economic cycle taking into account industry dynamics. The predictive model includes a neural network auto-encoder and an adapted deep convolutional network of the «WaveNet» architecture. The first function block reduces the dimension of the data. The second block predicts the phase of the economic cycle of the studied industry. A neural network uses the main components of the explanatory factors as input. The proposed model can be used both as an independent and an additional method for estimating the growth rate of the industrial production index along with dynamic factor models.

Каукин А.С., заведующий лабораторией системного анализа отраслевых рынков ИОРИ Российской академии народного хозяйства и государственной службы при Президенте РФ;

Косарев В.С., младший научный сотрудник лаборатории системного анализа отраслевых рынков ИОРИ Российской академии народного хозяйства и государственной службы при Президенте РФ.

Данная работа подготовлена на основе материалов научно-исследовательской работы, выполненной в соответствии с Государственным заданием РАНХиГС при Президенте Российской Федерации на 2019 год.

СОДЕРЖАНИЕ

| | |
|---|----|
| ВВЕДЕНИЕ..... | 4 |
| 1. Теоретические и эмпирические подходы к прогнозированию экономического цикла | 6 |
| 2. Разработка теоретической модели..... | 22 |
| 3. Данные для собственного эмпирического исследования..... | 26 |
| 3.1 Описание структуры базы данных | 27 |
| 3.2 Описание алгоритма формирования отдельных переменных | 30 |
| 4. Моделирование, верифицирование полученных результатов | 48 |
| 4.1 Обучение и тонкая настройка нейросетевой модели..... | 48 |
| 4.2 Верификация и валидация полученных результатов..... | 59 |
| 4.3 Описание полученных результатов, их интерпретация | 61 |
| ЗАКЛЮЧЕНИЕ | 65 |
| Список литературы | 68 |

ВВЕДЕНИЕ

Приступая к изучению циклических колебаний отечественной экономики, прежде всего стоит задаться вопросом: в какой степени отечественные кризисные явления являются следствием глобализации мировой экономики и в какой вызваны внутренними причинами? Относительно финансового кризиса 2009 г. в книге Р.М. Энтова [1] утверждается, что «кризис привнесен из вне, но фундаментальные причины носили весьма доморощенный характер». Аналогичный вопрос стал предметом серии научных работ Е.В. Беляновой [2, 3]. В процессе исследования были обнаружены признаки циклической динамики, проявившиеся в 18 лидирующих макроэкономических индикаторах. Это позволило авторам утверждать, что события 2008-2009 гг. назрели в силу внутренних закономерностей в большей степени, чем было принято считать, и воздействие мирового рынка лишь увеличило продолжительность экономического цикла и отдалило начало и без того надвигающегося кризиса на период от полугода до полутора лет. Таким образом, мы принимаем в качестве предпосылки, что неотъемлемая черта развития рыночной системы хозяйствования – деловой цикл, является характерной и для отечественной экономики.

Из классического определения экономического цикла Бернса и Митчела [4] следует, что цикл состоит из расширений и спадов, происходящих примерно в то же время во многих видах экономической деятельности. Для того, чтоб учитывать вклад отраслей в формирование общего экономического цикла в качестве его индикатора в мировой практике используется обычно ВВП или Индекс выпуска товаров и услуг по базовым видам экономической деятельности. Последний часто применяется в качестве основного синхронного индикатора российского экономического цикла. В литературе его иногда называют «эталонным» индикатором и используют вместо ВВП, поскольку последний имеет короткую историю, является квартальным и публикуется с двухмесячным лагом.

В своем подходе мы предлагаем изучать составляющие индекса выпуска товаров и услуг и прогнозировать его компоненты, а результаты прогнозов объединять в один диффузный индекс по следующему принципу: в экономике признается рецессия, если в большинстве секторов прогнозируется рецессия. Подобный подход дает возможность учитывать влияние специфических отраслевых факторов и позволяет отойти от нестабильно работающей концепции синхронных и опережающих индикаторов экономического цикла.

На настоящий момент мы прогнозируем состояние в четырех отраслях экономики, которые совместно создают существенную часть валовой добавленной стоимости,

благодаря чему взвешенный по ВДС индикатор из четырех отраслевых индексов достаточно точно повторяет динамику другого часто используемого прокси для российского экономического цикла – индекса промышленного производства.

Индикаторами состояния отраслей являются индексы производства по структуре ОКВЭД, два из которых относятся к разделу «добыча полезных ископаемых»:

- Добыча топливно-энергетических полезных ископаемых (CA);
- Добыча полезных ископаемых, кроме топливно-энергетических (CB);

И два к разделу «обрабатывающие производства»:

- Производство кокса, нефтепродуктов и ядерных материалов (DF);
- Metallургическое производство и производство готовых металлических изделий (DJ).

Логика построения прогноза для каждого индикатора заключается в следующем: сперва для индекса определяются поворотные точки, разграничивающие периоды роста и рецессии в прошлом, после чего с учетом набора объясняющих факторов оценивается вероятность наступления рецессии в следующем периоде.

Для определения поворотных точек нами был использован метод, который позволил исключить значительную долю субъективности. Данный метод был предложен Браем и Бошаном [5] и представляет собой алгоритмизированную процедуру NBER США для определения поворотных точек в отдельном макроэкономическом ряде. В работе отечественных исследователей (например, Дубовский, Кофанов [6]) алгоритм применялся для датировки поворотных точек в индексах: ВВП, промышленного производства базовых отраслей; инвестициях; запасах; их главных компонентах и показал устойчивые результаты. При этом полученные нами поворотные точки на пересекающейся части выборки (с 2000 по 2015 год) для отраслей из раздела добычи полезных ископаемых оказываются близки к выделенным фазам индекса промышленного производства (в который входит вид деятельности «Добыча полезных ископаемых») Дубовского; для отраслей из раздела обрабатывающие производства близки к индексу обрабатывающих производств.

Для построения прогнозов мы использовали сверточную нейронную сеть, а также полносвязную нейронную сеть и логистическую регрессию для сравнения прогностических характеристик.

Основная причина популярности нейронных сетей заключается в том, что они могут улавливать нелинейности и обеспечивать превосходную точность по отношению к линейным и нелинейным моделям без необходимости конструирования конкретной

параметрической модели [7]. Однако их параметры трудно интерпретировать, и превосходные характеристики на обучающей выборке не означают качественного прогноза для новых данных, то есть вне выборки. По этой причине мы уделяем значительное внимание проблеме переобучения. В частности, мы применяем алгоритмы снижения размерности для уменьшения количества оцениваемых параметров и используем специальную сверточную архитектуру нейронной сети. Расширенные свертки сети, в которых применяется фильтр, пропуская определенные элементы на входе, позволяют рецептивной части сети расти экспоненциально, тем самым позволяя, подобно рекуррентным сетям (обычно используемыми для анализа и прогнозирования временных рядов), получать доступ к широкому диапазону исторически данных. Преимущество сверточных сетей над рекуррентной сетью состоит в том, что из-за сверточной структуры сети количество обучаемых параметров значительно меньше, что приводит к гораздо более эффективному обучению и прогнозированию.

1. Теоретические и эмпирические подходы к прогнозированию экономического цикла

Существенное движение в сторону современного взгляда на экономические циклы в начале XX века произошло во многом по схожим обстоятельствам, связываемым с прорывом в начале XXI века в сфере, важной для настоящего исследования – машинного обучения: в обоих случаях взрывной интерес научного мира к теме обеспечил некоторый уровень накопленной статистики, пригодной для анализа. Эмпирическую революцию в теории экономического цикла совершила работа сотрудников NBER Бернса и Митчела [4]. Они впервые предложили определять состояние общей экономической активности посредством совпадающих и опережающих макроэкономических факторов. Позже этот подход получил дальнейшее развитие в работах сотрудников национального бюро экономических исследований США [8]. В результате этой работы был составлен список совпадающих, опережающих и запаздывающих индикаторов для экономики США, который использовался экономистами, политиками и прочими заинтересованными лицами в отслеживании и прогнозировании состояния макроэкономической деятельности на протяжении многих лет. В настоящее время существует большое количество циклических индикаторов и для других экономик, которые были разработаны в соответствии с методологией Бернса и Митчелла как на институциональном, так и на академическом уровне.

Любопытной представляется и эволюция системы опережающих индикаторов ОЭСР. Система составных опережающих индикаторов (CLI) ОЭСР была впервые

разработана в начале 1970-х годов на фоне возобновления интереса к исследованиям бизнес-циклов, что является прямым следствием рецессии 1969-1970 годов в развитых странах. Более глубокий и более глобальный экономический спад, последовавший в середине 70-х годов, усилил необходимость в таком инструменте, что привело к созданию в 1978 году специальной рабочей группы ОЭСР по циклическому анализу и опережающим индикаторам. Работа этой группы установила широкие критерии для CLI ОЭСР, базовая структура которых практически не изменилась с 1981 года.

В целом, как подчеркивали Сток и Ватсон [9]: «совпадающие и ведущие экономические индексы широко использовались бизнесом и правительством на протяжении десятилетий, но получили удивительно мало внимания со стороны ученых-экономистов».

Этот скептицизм ученых, вероятно, исходит из критики, выдвинутой Купмансом в 1947 г. [10], согласно которой первоначальная работа Бернса и Митчелла основана только на эмпирических закономерностях, поскольку все вычисления были сделаны с минимальным привлечением экономической теории. Купманс назвал проведенную работу «измерением без теории».

Кроме того, Сток и Ватсон [9] объясняют этот скептицизм также отсутствием четкого понимания того, что эффективно измеряют существующие совпадающие и опережающие экономические показатели. Другими словами, неясно, какая целевая переменная соответствует тому или иному совпадающему индексу.

Согласно Бернсу и Митчеллу, базовым циклом является так называемый деловой цикл, определяемый как «тип колебаний, обнаруживаемых в совокупной экономической активности стран, которые организуют свою работу главным образом на коммерческих предприятиях: цикл состоит из расширений, происходящих примерно в то же время во многих видах экономической деятельности последовали аналогичные общие спады, сокращения и оживления, которые сливаются в фазу расширения следующего цикла; эта последовательность изменений является периодической, но не строго переодичной; длительность деловых циклов варьируется от более одного года до десяти или двенадцати лет; они не делятся на более короткие циклы аналогичного характера с амплитудами, приближающимися к их собственным». Из приведенного выше определения следует, что бизнес-цикл не может быть выделен только из одного ряда, например, ВВП, а требует анализа ряда соответствующих показателей экономической деятельности. Несмотря на свою интуитивную привлекательность, определение не отражает какого-либо

количественного содержания, и это обстоятельство было признано также Бернсом и Митчеллом в их оригинальной работе.

Эти особенности побудили Стока и Ватсона разработать новые составные индексы совпадающих и опережающих индикаторов. Результаты их исследования впервые были опубликованы в журнале NBER в 1988 года. Затем методология была уточнена в трех других публикациях, появившихся в 1989 году, а затем в двух сборниках, появившихся в 1991 году (пересмотренная версия работы 1988 года) и в 1992 году. Идея этих работ заключается в построении вероятностной модели для построения индексов совпадающих и ведущих переменных, определяющих деловой цикл. Появлению индекса рецессии Стока и Ватсона предшествовало активное обсуждение в академической среде роли выявления и прогнозирования поворотных точек экономического цикла.

Дискуссия касалась, с одной стороны, традиционного взгляда аналитиков бизнес-циклов, согласно которому сокращения и восстановления являются частью макроэкономического процесса, наблюдаемого статистически, даже если поведение агентов представлено различными функциями, отражающими асимметрию в их поведении в период рецессии и экспансионистские периоды. Тогда, согласно этой точке зрения, циклическое поведение экономики имеет «внутреннюю» интерпретацию. С другой стороны, группа экономистов поддержала идею о том, что в макроэкономической циклической эволюции не было ничего общего с изменениями в экономическом поведении агентов; скорее расширения и сокращения являются «результатами стабильной структуры, адаптирующейся к случайным ударам» [9]. Следовательно, в подходе Стока и Ватсона, начало которому было положено Бернсом и Митчелом, преобладает «внешняя» интерпретация рецессий и экспансий, влияющих на экономику. Эта точка зрения содержится как в совпадающих, так и в ведущих индексах Стока и Ватсона, а также соответствует их предложению относительно индекса рецессии. Индекс рецессии определяется как «оценка вероятности того, что экономика будет находиться в рецессии через шесть месяцев». На вероятность нахождения индекса в рецессии влияют преимущественно внешние шоки, которые первостепенно проявляются в опережающих индикаторах, входящих в модель.

Возвращаясь к определению экономического цикла Бернса и Митчела стоит сказать, что, не смотря на его общепринятую авторитетность, нераскрытым остается входящий в него термин «совокупная экономическая активность», колебания которой и признаются циклическими колебаниями экономики. Не раскрытым имеется в виду в классической работе непосредственно исследователей. Из работы не следовало, что, например, должно быть основой для измерения или определения «экономической

активности» и как цикл должен взвешивать эти многочисленные виды экономической деятельности, чтобы достичь совокупности. «Совокупная экономическая активность» явно предлагает единственную меру, в которой реальный ВВП, измеряющий все производство в денежном выражении в стране, является индикатором всей экономики. Однако экономическая деятельность не обязательно определяется таким образом. Альтернативные показатели экономической активности могут быть сфокусированы на многих других переменных, таких как занятость, создание новых предприятий, благосостояние, международная торговля и т.д. Как и ВВП, они могут служить единственной основой для определения делового цикла, но их можно также объединить в составную взвешенную и нормализованную форму для создания составного совпадающего показателя делового цикла.

В этом контексте интересно рассмотреть вопрос о том, каким образом данная задача была решена национальным бюро экономических исследований США (NBER). Для NBER рецессия – «это значительное снижение экономической активности, распространяющейся по экономике, которая длится более нескольких месяцев и обычно наблюдается в реальном ВВП, реальном доходе, занятости, промышленном производстве и оптово-розничных продажах». В дебатах, ведущих к созданию системы ведущих индикаторов ОЭСР, было рассмотрено множество подходов. Участвующие страны-члены ОЭСР предложили в общей сложности 15 различных способов выражения концепции совокупной экономической активности, прежде чем окончательно решить вопрос о целевом реальном ВВП «в качестве единственной наиболее важной целевой переменной» [8].

Однако на практике ОЭСР, по крайней мере, до апреля 2012 года бизнес-цикл обязательно определялся для оперативных целей на основе индекса промышленного производства (ИПП). Это отражало тот факт, что длина ряда реального ВВП, необходимая для количественной оценки эталонного бизнес-цикла, была доступна на ежеквартальной основе только для половины стран-членов. Вместо этого индекс промышленного производства был доступен для всех стран-членов ОЭСР ежемесячно и ежеквартально. Так же отмечается тот факт, что индекс промышленного производства представлял собой наиболее «циклический» компонент ВВП, на который приходилось примерно 35% доли валовой добавленной стоимости в середине 1980-х годов. Промышленный сектор, являясь значительным потребителем услуг, также стимулировал поставки в значительную часть частного сектора услуг.

Тем не менее несмотря на то, что в настоящее время система опережающих индикаторов ОЭСР принимает ВВП в качестве основы для определения бизнес-цикла, остаются вопросы относительно того, какую именно метрику в бизнес-цикле ВВП следует учитывать.

Как правило рассматриваются три варианта:

1. Классический вариант бизнес-цикла, который определяет бизнес-циклы на основе значений индекса реального ВВП. Периоды положительного роста (расширения) и отрицательного роста (классического сокращения) используются для определения цикла.

2. Отклонение от цикла тренда (часто называемого циклом роста и связано с разрывом в выпуске¹), при котором из динамики реального ВВП удаляются устойчивые долгосрочные тренды. При это в один классический цикл может уложиться несколько циклов роста.

3. Цикл темпов роста, основанный на темпах роста базового ряда, с периодами ускорений и замедлений роста.

Различные типы циклов, приведенные выше, не являются простой семантикой: хотя базовые бизнес-циклы могут быть «в целом» похожими, поворотные точки будут различаться. В частности, цикл темпов роста обычно дает больше точек поворота (и, следовательно, больше циклов), чем другие варианты. Поэтому важно учитывать, какой из трех вариантов следует использовать в качестве цели, особенно потому, что выбор цикла критически влияет на выбор составных показателей.

Система опережающих индикаторов ОЭСР фокусируется на отклонении от тренда, потому что эта мера, как правило, лучше приспособлена для удовлетворения потребностей политики, связанной с управлением бизнес-циклами. Поскольку ОЭСР выполняет исследования для всех стран-членов организации, то по необходимости для определенной страны может быть посчитан «классический бизнес-цикл» и «цикл темпов роста». В этом контексте важно отметить, что отдельные показатели, используемые при построении общего составного показателя для определенной страны, выбираются и оптимизируются на основе показателя отклонения от тренда.

На рисунке 1 представлены этапы процесса построения композитного индекса ОЭСР. В различных блоках схемы продемонстрированы процедурные шаги, которые

¹ Разрыв выпуска - концепция, являющаяся центральным для формирования фискальной и денежно-кредитной политики - обычно определяется как разница между фактическим объемом производства и потенциальным объемом производства. Поскольку потенциальный выпуск продукции не наблюдается, используются различные методы для его оценки. Простой, чисто эконометрический метод определяет потенциальный результат на основе тренда.

выполняются при построении индекса впервые, либо при пересмотре и верификации существующего решения.

На этапе предварительного выбора определяется справочный ряд и весь доступный набор макроэкономических индикаторов. Предварительно размеченный справочный ряд является эталонным, т.е. в соответствии с фазами экономического цикла, определенными на нем, происходит выявление опережающих и запаздывающих индикаторов.

На втором этапе происходит фильтрация рядов данных: осуществляется сезонная корректировка при необходимости, удаляются выбросы, и наконец определяются циклические компоненты рядов.

Далее проверяется отклонение цикла от тренда в рядах – потенциальных кандидатах на роль лидирующих индикаторов и сохраняется более короткий список таких кандидатов. При эвристическом поиске несколько комбинаций индикаторов из короткого списка составляются в конкурирующие CLI на этапе агрегации, затем эти варианты последовательно проверяются на соответствие бизнес-циклу, который определяет отобранный ранее эталонный или справочный ряд.

Функция потерь, сочетающая статистические свойства и практические соображения, используется для ранжирования различных вариантов CLI.



Рисунок 1 – Схема конструкции композитного индекса ОЭСР

Как отмечалось выше, предпочтительным выбором ОЭСР в качестве справочного ряда является ВВП. Однако в 1980-х годах подходящие временные ряды по ВВП были недоступны во многих странах ОЭСР. До марта 2012 года система составных опережающих индикаторов ОЭСР использовала индекс промышленного производства (ИПП) в качестве косвенного ориентира для бизнес-цикла. ОЭСР в основном опирается на наборы данных экономической статистики, собранные статистическим управлением, которые охватывают многие направления, такие как:

1. ВВП и его составляющие;
2. переменные промышленного производства и отдельных товаров;
3. серия опросов деловых и потребительских тенденций;
4. выбранные производственные переменные (продажи, запасы, заказы и т. д.);
5. индикаторы из других секторов промышленности / бизнеса (например, строительство, розничная торговля / оптовые продажи);

6. статистика рынка труда;
7. потребительские и производственные цены;
8. денежные агрегаты;
9. процентные ставки, курсы валют и цены на активы;
10. данные по международной торговле и платежному балансу.

Помимо собственных данных ОЭСР, набор индикаторов дополняется статистикой, собранной специально для тестирования в рамках CLI национальными статистическими ведомствами, центральными банками или другими поставщиками данных. Кроме того, ОЭСР часто получает помощь и советы экспертов от статистиков и экономистов научных институтов.

При выборе составляющих системы опережающих индикаторов ОЭСР полагается на следующие критерии:

1. Экономическое значение: наблюдение статистической связи между выбранным индикатором и справочным рядом само по себе недостаточно - также необходимо экономическое обоснование этой взаимосвязи;
2. Ширина охвата: ряды с широким охватом экономической активности предпочтительнее узконаправленной статистики;
3. Периодичность: месячные ряды предпочтительнее квартальных;
4. Пересмотр: ряды, которые не подлежат существенным пересмотрам, являются предпочтительными. По той же причине гладкие ряды также предпочтительнее шумных рядов. Шум делает опережающий сигнал более неоднозначным и преобразуется в циклическую компоненту с помощью сглаживающего фильтра, который применяется ко всем рядам;
5. Своевременность: данные должны быть доступны после окончания отчетного периода;
6. Длина: длинные временные ряды без разрывов предпочтительнее коротких временных рядов, так как последние могут препятствовать надежной оценке взаимосвязей между опережением и отставанием из-за уменьшенного числа поворотных точек, которые они включают;

Потенциальные опережающие индикаторы обычно соответствуют одному из четырех типов экономических обоснований, приведенных ниже:

1. Ранняя стадия: индикаторы, измеряющие ранние стадии производства, такие как: новые заказы, разрешения на строительство и т. д.;

2. Быстро реагирующие: индикаторы быстро реагируют на изменения в экономической активности, такие как: средние отработанные часы, прибыль и акции.

3. Чувствительные к ожиданиям: индикаторы, измеряющие или чувствительные к ожиданиям, таким как цены на акции, цены на сырье, ожидания, основанные на данных бизнес-опросов, касающихся производства или общей экономической ситуации / климата, например – показатели доверия и т.д.

4. Основные факторы: показатели, касающиеся денежно-кредитной политики и развития внешнеэкономической деятельности, такие как предложение денег, условия торговли и т. д.

Несмотря на то, что между агрегированным показателем и показателями четырех, приведенных выше категорий, может существовать взаимосвязь «один ко многим», система опережающих индикаторов пытается сбалансировать состав входящих факторов путем включения показателей из каждой из четырех категорий.

Сбалансированный набор показателей позволяет воспользоваться преимуществами составного показателя, в отличие от единичных индикаторов делового цикла: эффективно предсказывать развивающиеся циклы и демонстрировать устойчивость к шуму, характерному для каждого отдельного временного ряда, но исчезающему в составных показателях.

Анализ эмпирических работ отечественных исследователей

В отечественной академической литературе существует ряд работ, где проводится глубокий анализ макроэкономических индикаторов на возможность их отнесения к опережающим, запаздывающим и совпадающим. Во многом эти работы являются попыткой адаптировать зарубежные подходы, в первую очередь таких организаций как NBER и OECD, к реалиям отечественных циклических процессов. Впрочем, прежде чем перейти к анализу непосредственно индикаторов экономического цикла, отечественные исследователи задавались справедливым вопросом: а имеет ли в принципе российская экономика внутренние механизмы цикличности или же она только импортирует внешние циклы? Однозначно на этот вопрос отвечает Е. Белянова и С. Николенко [2], утверждая, что в различных сферах экономической деятельности в России, таких как реализация продукции, эффективность производства, ресурсные ограничения ожидания экономических агентов и пр., проявляются признаки циклических механизмов. Это дает им основания перейти к следующему этапу: определению опережающих показателей экономического цикла, фазы которого были определены с использованием индекса

промышленного производства². В определении опережающих индикаторов авторы следовали методологии NBER. На основе нескольких сотен индикаторов, которые NBER относит к различным группам лидирующих, ими были составлены отечественные аналоги. Итоговый набор индикаторов, для которых доступна статистика в России, предоставлен в таблице 1.

Таблица 1 – Аналоги лидирующих индикаторов экономического цикла NBER по которым доступна российская статистика

| Название индикатора | Описание |
|--------------------------|---|
| Курсы акций | Фондовый индекс РТС, средний за месяц приведенный к базовому году. |
| Доходность | Эффективная доходность RUX Cbonds. |
| Спрэд доходности | Разница между эффективными доходностями RUX Cbonds и ОБР. |
| Заказы в промышленности | Стоимость заказов по отношению к стоимости отгруженной продукции. |
| Заказы в строительстве | Стоимость заказов по отношению к месячной стоимости строительных работ. |
| Производство цемента | Месячное производства цемента |
| Прибыль в промышленности | Отношение прибыли крупных и средних промышленных предприятий по отношению к стоимости отгруженной продукции за месяц. |
| Прибыль в экономике | Отношение прибыли крупных предприятий к ВВП с интерполяций последнего на месячные данные. |
| Запасы в промышленности | Отношение запасов к стоимости отгруженной продукции. |
| Запасы в торговле | Отношение к стоимости розничных продаж. |
| Денежная масса | Денежная масса M2, дублированная |

² Индекс был приведен к единой базе и очищен от сезонных колебаний. При этом замечается, что с весны 2010 года Росстат начал публиковать очищенный от сезонности ИПП, но в ретроспективе лишь до 2008 года.

| | |
|--|---|
| | на ИПЦ к базовому периоду. |
| Индекс предпринимательской уверенности | Опросные данные |
| Безработица | Число зарегистрированных безработных в месяц службой занятости. |

Продолжение таблицы 1

| | |
|-----------------------------------|---|
| Темп роста безработных | Темп роста безработных, состоящих на учете в службе занятости. |
| Индекс потребительских настроений | Опросные данные |
| Сальдо текущего баланса | Сальдо текущего платежного баланса, интерполируются из квартальных данных. |
| Чистые иностранные активы банков | Чистые иностранные активы банковской системы по отношению ко всем банковским активам. |

Источник: работа Е. Белянова и С. Николенко [2]

Отобранные Е. Беляновой и С. Николенко индикаторы были проверены на возможность предсказывать экономический цикл. Авторы сопоставляли динамику приведенных рядов с переломной точкой, отражающей начало финансово-экономического кризиса 2008 года, которую демонстрировал сглаженный индекс промышленного производства. В результате оказалось, что все без исключения отобранные индикаторы заблаговременно оповещали о начале рецессии.

Аналогичная работа была проделана в работе Ю. Адериho [11], где на основе базы данных NBER также были отобраны показатели, которые имеют доступные аналоги в отечественной статистике. Итоговая таблица помимо перечисленных выше включает показатель: «число первичных заявлений на получение пособий по безработице». Практическим результатом работы является ранжирование отобранных показателей по их прогностическим возможностям. Отдельно проводилось ранжирование индикаторов для входа в рецессию и выхода из нее. К примеру, высокий ранг, как для входа, так и для выхода, в соответствии с наблюдениями авторов, имеют индекс потребительских ожиданий и среднее за неделю число первичных заявлений на получение пособий по безработице.

В работе А. Пестовой [12] используется модельный подход для построения индикаторов экономической активности ряда стран, но особое внимание уделено России. Модель бинарного выбора (logit-модель) определяет вероятность наступления рецессии в зависимости от состояния факторов, которые были отобраны по следующим блокам:

1) Блок переменных реального сектора (опережающие индикаторы ВВП по методологии ОЭСР; индексы потребительской и бизнес-уверенности; динамика инвестиций и ВВП; импорт строительных материалов; производство электроэнергии; реальный эффективный валютный курс; счет текущих операций);

2) Блок переменных финансового сектора (фондовые индексы; процентные ставки и спреды между ними; динамика кредитования и ликвидности банков).

В работе отмечается, что все перечисленные переменные оказались значимыми и ожидания относительно направленности влияния (ацикличности и процикличности факторов) оправдались.

Кроме частных научных инициатив, большой вклад в развитие теории опережающих индикаторов, вносят российские исследовательские центры, государственные органы и частные компании. Некоторый обзор таких организаций, а также используемых ими методологий, приведен в работах А. Киселева [13] и О. Демидова [14]. Отдельно стоит отметить работу С. Смирнова [15], которая включает в себя приложение «сводные циклические индикаторы для России: полный спектр». Часть из них уже не рассчитывается, а часть все еще актуальна.

Следуя перечисленным работам, приведем перечень наиболее авторитетных организаций, занимающихся построением опережающих индикаторов, и их методологий, как на основе диффузных индексов, так и на основе статистических и эконометрических методов. За наиболее полным перечнем и подробным разбором методологии можно обратиться к оригинальным работам и публикациям самих организаций [16].

Диффузный индекс HSBM PI, построением которого занимается Евразийская экономическая комиссия (ЕЭК), основан на опросных данных 300 российских компаний обрабатывающих отраслей. Построение индекса происходит путем суммирования ответов, которые характеризуют рост или снижение ожидаемых объемов производства, занятости, объемов запасов сырья и материалов и т.п. На основе этих же данные с некоторыми весами выводится конъюнктурный индекс.

Центр развития НИУ ВШЭ ежемесячно публикует сводный запаздывающий индекс (СЗИ), сводный синхронный индекс (ССИ), сводный опережающий индекс (СОИ). Система индексов основана на концепции циклов роста, т.е. все ряды рассматриваются с

исключенным трендом. Сводный синхронный индикатор рассчитывается, как взвешенное среднее из темпов прироста индексов физического объема по отраслям экономики, на которые приходится около половины ВВП. В эти отрасли входят:

- 1) Добывающая и обрабатывающая промышленность;
- 2) Сельское хозяйство;
- 3) Строительство;
- 4) Грузоперевозки;
- 5) Розничная торговля;
- 6) Платные услуги.

Процесс построения сводного опережающего индекса предполагает ряд шагов.

Первоначально датируются поворотные точки сводного совпадающего индекса или индекса промышленного производства, очищенного от сезонности. Затем датируются поворотные точки для 40 выбранных кандидатов в опережающие индикаторов, из которых, в соответствии с опережающими характеристиками, отбирается семь. В настоящее время среди семи опережающих индикаторов находятся следующие:

- 1) Среднемесячная цена нефти Urals;
- 2) Процент предприятия с растущим и неизменным спросом (опросные данные ИЭП);
- 3) Процент предприятий без избыточных запасов (опросные данные ИЭП);
- 4) Номинальная процентная ставка MIACR-overnight (средняя за месяц);
- 5) Реальный эффективный курс рубля (на конец месяца);
- 6) Индекс РТС (на конец месяца);
- 7) Прирост денежной массы M2 (на конец месяца).

В конечном итоге сводный опережающий индикатор составляется, как взвешенное по стандартным отклонениям среднее из нормированных отобранных индикаторов.

Опережающий индикатор ВВП РенКап-РЭШ на данный момент не рассчитывается, но в прошлом высоко ценился рынком за его высокие прогностические качества [13], а также за ранние публикации: прогноз выходил раньше прогноза Минэнерго и Росстата, публикующего свой прогноз после конца квартала через полтора месяца. Построение индекса предполагало следующие шаги:

- 1) Первоначальный набор объясняющих факторов подвергался предобработке (остационарирование, снижение шума), после чего выбирались факторы, которые обладали лучшими прогностическими способностями.

2) Из отобранных факторов выделялись главные компоненты, в результате чего оставалось несколько факторов, содержащих важную информацию от всего отобранного пула.

3) При помощи фильтра Калмана дополнялись незаполненные значения последних периодов рядов, по которым существовала задержка в публикации.

4) Прогноз для ВВП строился при помощи стандартной линейной регрессии (МНК), где в качестве объясняющих факторов, кроме выделенных компонент, также присутствовали лаг ВВП.

При этом спецификация модели могла меняться в зависимости от оптимального количества лагов, которые определялись при каждом пересчете с учетом информационных критериев. Среди преимуществ индикатора называется также его интерпретируемость, поскольку прогноз индекса – это прогноз реального ВВП.

Система опережающих индикаторов (СиОИ) ЦМАКП является многовариантной. Она включает в себя различные индикаторы для отдельных рисков: кредитных, ликвидности, валютный. Кроме того, в различных фазах экономического цикла используются различные параметры в прогнозной модели. Базовая модель – это модель бинарного выбора (logit или probit-модель), которая прогнозирует вероятность наступления рецессии. В бескризисную фазу порог, обозначающий вероятность наступления кризиса, устанавливается ниже, чем в предкризисные периоды.

Опережающие индикаторы Евразийской Экономической Комиссии (ЕЭК) рассчитываются для всего перечня стран, входящих в союз. В основе методологии построения индикаторов находится система ОЭСР для построения композитных опережающих индикаторов. Наборы опережающих макроэкономических показателей определяются для каждой страны индивидуально. Общая схема построения выглядит следующим образом:

1) Для страны выбирается базовый ряд, характеризующий общую экономическую активность страны на месячной основе. Как правило это сводный совпадающий индикатор, рассчитываемый ЕЭК на основе индексов производства по основным видам экономической деятельности.

2) Выбирается пул возможных факторов-кандидатов на роль опережающих факторов. Производится их предобработка: ряды приводятся к сопоставимым ценам, прогнозируются крайние точки при помощи ARIMA, ряды остационариваются, очищаются от сезонности, удаляются выбросы по правилу трех стандартных отклонений, сглаживаются при помощи фильтра Спенсера, стандартизируются.

3) Предполагаемые лидирующие переменные датируются при помощи алгоритма Бря-Бошана, который позволяет механически определить поворотные точки. Из имеющегося пула обработанных данных выбираются лидирующие по отношению к базовой переменной факторы при условии опережения не менее, чем на три месяца.

4) Затем используется четыре критерия, которые определяют опережающие характеристики индикаторов:

5) В конечном итоге сводный опережающий индикатор рассчитывается по следующей формуле (1).

$$COI_t = 100 + \frac{\sum_{i=1}^N L^{\text{lag}(x_t)-t}(x_i) * \text{sgn}(\text{corr}(x_i; y))}{N} \quad 1)$$

Где,

y – сводный совпадающий индикатор; x_i – i-й опережающий индикатор;

L – лаговый оператор; t – лаг, с которым сводный опережающий индикатор должен опережать совпадающий индикатор;

N – число опережающих индикаторов.

Как следует из формулы, сводный опережающий индикатор ЕЭК имеет только качественную интерпретацию, но не количественную.

Опережающий индекс финансовой стабильности был разработан и в институте им. Гайдра совместно с компанией «Открытие Капитал» в 2011 году, однако на данный момент не рассчитывается. Индекс был основан на взвешенных значениях следующих опережающих показателях:

- 1) Денежный агрегат М2;
- 2) Отношение М2 к золотовалютным запасам;
- 3) Отношение М2 к денежной базе;
- 4) Базовый ИПЦ;
- 5) Международные резервы;
- 6) Межбанковская процентная ставка;
- 7) Реальный курс рубля к доллару;
- 8) Среднесрочная и долгосрочная ставки по ГКО-ОФЗ;
- 9) Индекс РТС;
- 10) Индексы корпоративных облигация РТС, ММВБ;
- 11) Индекс государственных облигаций ММВБ;
- 12) Депозиты коммерческих банков в центральном банке и облигации ЦБ в коммерческих банках.

Стоит также отметить композитный опережающий индикатор экономического цикла ОЭСР. Его методология достаточно полно описана в документах ОЭСР [17]

Таблица 2 – Опережающие индексы российского экономического цикла, публикуемые в настоящий момент и публиковавшихся ранее

| | Состояние на май 2019 года | Периодичность публикации |
|---|----------------------------|--|
| Диффузный индекс HSBM PI | Не рассчитывается | - |
| СОИ Центр развития НИУ ВШЭ | Рассчитывается | Ежемесячно Помесечный прогноз на год вперед |
| Опережающий индикатор ВВП РенКап-РЭШ | Не рассчитывается | - |
| Опережающие индикаторы ЕЭК | Рассчитывается | Ежемесячно Прогноз на 3, 6 месяцев и год вперед |
| Опережающий индекс финансовой стабильности ИЭП им. Гайдара и «Открытие Капитал» | Не рассчитывается | - |
| Composite Leadig Indicator OECD | Рассчитывается | Ежемесячно |

Стоит отметить, что индекс СОИ Центра Развития ВШЭ оказался способными предсказать заранее кризис 2008 года, сделав это за шесть месяцев до общепризнанной точки входа в рецессию. Однако внимание общественности и политических сил это не привлекло.

В заключении раздела стоит подчеркнуть факт отсутствия для России общепринятой методологии определения поворотных точек экономического цикла, на что обращалось внимание в ряде упомянутых выше исследований [2, 14]. В связи с этим различные исследователи предлагают отличные друг от друга подходы. Это касается, как выбора опережающих индикаторов, так и способа обнаружения поворотных точек на отдельном временном ряде и поиска общих точек в кластере, характеризующих совокупную экономическую активность. Отсюда вытекает и ряд противоречий между работами отечественных исследователей. К примеру, Е. Беляновой [2] был проделан

серьезный труд по отбору опережающих индикаторов экономической активности аналогичным набору рекомендованных OECD. Однако, Смирнов и Кондрашов [18] подвергли критике выводы Е.Беляновой, утверждая, что часть из приведенных индикаторов не является релевантной для отечественной экономики, поскольку в действительности они являются запаздывающими. Позже Кофанов и Сосунов [6] их использовали для определения поворотных точек на исторических данных в качестве совпадающих индикаторов. В целом же по проанализированным моделям, как отдельных исследователей, так различных организаций, также не наблюдается какого-либо единства в отнесении макрофакторов к опережающим и запаздывающим. От части это связано с тем, что модели создавались в разные периоды и учитывали опыт определенных финансовых потрясений, в то время как более длинные ряды и новые кризисные явления заставляли исследователей пересмотреть существующие результаты.

2. Разработка теоретической модели

Из классического определения экономического цикла Бернса и Митчела следует, что цикл состоит из расширений и спадов, происходящих примерно в одно то же время во многих видах экономической деятельности. Для того, чтоб учитывать вклад отраслей в формирование общего экономического цикла в качестве его индикатора в мировой практике используется обычно ВВП или Индекс выпуска товаров и услуг по базовым видам экономической деятельности. Последний часто применяется в качестве основного синхронного индикатора российского экономического цикла. В литературе его иногда называют «эталонным» индикатором и используют вместо ВВП, поскольку последний имеет короткую историю, является квартальным и публикуется с двухмесячным лагом.

В своем подходе мы предлагаем изучать составляющие индекса выпуска товаров и услуг и прогнозировать его компоненты, а результаты прогнозов объединять в один диффузный индекс по принципу: в экономике признается рецессия, если в большинстве секторов прогнозируется рецессия. Подобный подход дает возможность учитывать влияние специфических отраслевых факторов и позволяет отойти от нестабильно работающей концепции синхронных и опережающих индикаторов экономического цикла.

Выбранные компоненты индекса отражают состояние в четырех отраслях экономики, индикаторами которых являются индексы производства по структуре ОКВЭД. Два из них относятся к разделу «добыча полезных ископаемых»: добыча топливно-энергетический полезных ископаемых (СА); добыча полезных ископаемых, кроме топливно-энергетических (СВ). И два к разделу «обрабатывающие производства»:

производство кокса, нефтепродуктов и ядерных материалов (DF); металлургическое производство и производство готовых металлических изделий (DJ).

На рисунке 2 изображена динамика обозначенных индексов на фоне изменения индекса физического объема ВВП.




Рисунок 2 – Индексы производства выбранных отраслей и индекс физического объема ВВП, квартальные данные.

В предлагаемых четырех отраслях экономики создается существенная часть валовой добавленной стоимости, благодаря чему взвешенный по ВДС индикатор из четырех отраслевых индексов достаточно точно повторяет динамику индекса физического объема ВВП (рисунок 3).



Рисунок 3 – Сумма взвешенных по ВДС индексов производства выбранных отраслей и ИФО ВВП

Кроме того, взвешенные индексы хорошо повторяют динамику другого часто используемого прокси для российского экономического цикла – индекса промышленного производства (рисунок 4).



Рисунок 4 – Сумма взвешенных по ВДС индексов производства выбранных отраслей и индекса промышленного производства

На рисунке 5 представлена совместная динамика индекса физического объема ВВП и индекса промышленного производства по секторам C,D,E по структуре ОКВЭД 2007.



Рисунок 5 – Наложение индексов производства и физического объема ВВП.

Динамика взвешенных индексов свидетельствует о том, что оценка состояния выбранных четырех отраслей может быть аппроксимирована на состояние всей экономики. Таким образом для прогнозирования совокупной экономической активности мы будем искать поворотные точки в этих индексах, прогнозировать их, а результаты объединять в некоторый справочный индекс.

Для того, чтоб перейти от поворотных точек индексов к поворотным точкам экономического цикла, была применена концепция диффузного. Бинарной переменной приписывается нулевое значение (что соответствует фазе спада), когда более половины составляющих диффузного индекса (то есть 3 из 4 ИПП) сигнализируют о переходе в фазу рецессии.

При этом стоит оговорить причины, по которым концепция опережающих индикаторов, применяемая в развитых странах, работает нестабильно. К примеру, NBER

США используют четыре опережающих индикатора для определения перехода экономического цикла в новую фазу: общая численность занятых в несельскохозяйственном секторе, реальные доходы населения, индекс промышленного производства и продажи промышленной продукции. По мнению отечественных исследователей [15] для российской экономики применение такого подхода не представляется возможным по ряду причин. Во-первых, во время кризиса российские компании стараются избежать сокращения персонала, предпочитая замораживать или даже уменьшать номинальную заработную плату. Во-вторых, российские кризисы обычно сопровождаются девальвацией рубля, которая и сама какое-то время сдерживается Банком России, но еще более отложенным последствием которой является взрывной рост внутренних цен. В итоге не только показатели российского рынка труда не являются синхронными, но и пики «реальных» индикаторов, рассчитанных путем дефлирования, могут сдвигаться вправо относительно истинного начала кризиса.

В силу того, что общепринятой классификации поворотных точек нет, мы обратились к зарубежному и отечественному опыту в поисках алгоритмической процедуры, которая бы минимизировала ручное вмешательство в процесс определения фаз цикла на исторических данных, а, следовательно, исключала субъективное представление исследователя.

Из приведенного выше анализ академической литературы следует, что процедура Брая-Бошана (предложена Bry, Boschan, 1971; фактически алгоритмизированная процедура NBER США для определения поворотных точек в отдельном макроэкономическом ряде) является наиболее предпочтительной для определения поворотных точек экономического цикла. В работах отечественных исследователей [3, 18, 6] алгоритм применялся для датировки поворотных точек в индексах: ВВП, промышленного производства базовых отраслей; инвестициях; запасах; их главных компонентах и других. Во всех перечисленных работах алгоритм показал устойчивые результаты, а в исследовании Смирнова продемонстрировал свое превосходство над моделью с марковскими переключениями (предложена Hamilton, 1998), которая генерировала значительное число ложных поворотных точек.

Следующим этапом является построение самой прогнозной модели. В существующих эмпирических работах, посвященных опережающим индикаторам макроэкономических кризисов, зависимая переменная фазы бизнес-цикла (состояния экономики), отражает в самом простом случае два возможных исхода — рецессию или экспансию. Мы так же прогнозируем два состояния отрасли, для чего и предполагается

проводить датировку поворотных точек, решая, таким образом, типичную задачу классификации.

Гибким, улавливающим сложные нелинейности и хорошо зарекомендовавшим себя в различных сферах классификатором, является нейронная сеть. Однако прогноз нейросети, как и любой прогноз математической модели имеет инерционный характер, поскольку в процессе подбора параметров «эксплуатируются» зависимости между факторами в ретроспективе. Для построения качественного прогноза важно не переобучить модель, т.е. не создавать такую сложную функцию (чем в сущности и является нейронная сеть), которая бы идеально описывала данные в ретроспективе, но теряла при этом возможности абстракции и плохо прогнозировала будущее. Нейронные сети считаются датазатратными методами и для того, чтоб не возникала проблема переобучения рекомендуется не допускать отношения числа наблюдений к числу оцениваемых параметров меньше, чем 1 к 10. Возможность соблюдения данного эмпирического правила в нашем случае обеспечивает специально выбранная архитектура – сверточная нейронная сеть. Количество параметров в такой сети, которые требуется обучить, в разы меньше, чем в другого рода архитектурах (полносвязных и рекуррентных) при прочих равных. Кроме того, важным преимуществом является возможность учитывать пространственно-временной порядок данных. Предлагаемая модель для каждой отрасли строит краткосрочный прогноз (на 1 месяц и на 1 квартал) вероятности нахождения в фазе рецессии, используя в качестве входных данных: месячные значения уровня индивидуального индекса промышленного производства и три выделенные главные компоненты.

3. Данные для собственного эмпирического исследования

База данных собственного эмпирического исследования в части объясняемых переменных состоит из индексов производства четырех отраслей. Как известно, с января 2017 Росстат перешел на новый классификатор экономической деятельности ОКВЭД2, что крайне осложняет работу со статистикой промышленного производства. В таблице 3 приведены отличия в структуре ОКВЭД2007 и ОКВЭД2 для выбранных отраслей. Раздел «Добыча топливно-энергетических полезных ископаемых» старого классификатора в новом был разбит на два раздела: «Добыча угля» и «Добыча полезных ископаемых». Раздел ОКВЭД2007 «Добыча полезных ископаемых, кроме топливно-энергетических» также разделен на два: «Добыча металлических руд» и «Добыча прочих полезных ископаемых». Агрегат «Производство кокса и нефтепродуктов» остался без изменений в новом классификаторе. Раздел «Металлургическое производство и производство готовых

металлических изделий» было разделено на два раздела: «Производство металлургическое» и «Производство готовых металлических изделий, кроме машин и оборудования». При этом, ретроспективно по новой классификации Росстатом индексы пересчитаны только до 2013 года.

Таблица 3 – Различия между классификаторами экономической деятельности ОКВЭД2007 и ОКВЭД2 для выбранных отраслей.

| ОКВЭД-2007 | ОКВЭД2 (с 1 января 2017 г.) |
|--|---|
| Раздел С. Добыча полезных ископаемых | Раздел В. Добыча полезных ископаемых |
| СА. Добыча топливно-энергетических полезных ископаемых | 05. Добыча угля 06. Добыча сырой нефти и природного газа |
| СВ. Добыча полезных ископаемых, кроме топливно-энергетических | 07. Добыча металлических руд 08. Добыча прочих полезных ископаемых |
| | 09. Предоставление услуг в области добычи полезных ископаемых |
| Раздел D. Обрабатывающие производства | Раздел С. Обрабатывающие производства |
| DF. Производство кокса и нефтепродуктов | 19. DF. Производство кокса и нефтепродуктов |
| DJ. Металлургическое производство и производство готовых металлических изделий | 24. Производство металлургическое 25. Производство готовых металлических изделий, кроме машин и оборудования |

Источник: Каукин, Миллер, 2017.

Для того, чтоб иметь максимально возможную длину временных рядов мы пересчитываем индексы из ОКВЭД2 в ОКВЭД2007 по методологии ИЭП [19], поскольку статистика по старой методологии доступна с 2002 года и мы заинтересованы в том, чтоб иметь максимально возможный временной горизонт наблюдений. Для пересчета индексов из нового классификатора применяются веса по структуре валовой добавленной стоимости. Индексы, соответствующие входящим ранее в раздел отраслям, складываются с весами пропорциональными вкладу отраслей в ВДС.

3.1 Описание структуры базы данных

В результате проведенного анализа для построения прогнозной модели нами были отобраны факторы в соответствии с их опережающими характеристиками. Перечень отобранных факторов представлен в таблице 4. Данные структурированы по трем блокам: реальный сектор, финансовый сектор, ожидания экономических агентов. Все данные были взяты из открытых источников: Росстат (отраслевая статистика), Банк России

(финансовые макрофакторы), Финам (стоимость нефти), World Bank (ВВП стран импортеров).

Таблица 4 – Набор выделенных объясняющих факторов с разделением по группам

| Объясняемые переменные | | |
|--------------------------------|--|--|
| Группа | Название | Описание/ источник/ частотность |
| Индексы производства | Добыча топливно-энергетический полезных ископаемых (СА) | Индекс производства, Росстат, 2005-2018, месяц. |
| | Добыча полезных ископаемых, кроме топливно-энергетических (СВ) | Индекс производства, Росстат, 2005-2018, месяц. |
| | Производство кокса, нефтепродуктов и ядерных материалов (DF) | Индекс производства, Росстат, 2005-2018, месяц. |
| | Металлургическое производство и производство готовых металлических изделий (DJ) | Индекс производства, Росстат, 2005-2018, месяц. |
| Объясняющие переменные | | |
| | | Описание/ источник/ частотность |
| Ожидания экономических агентов | Индекс предпринимательской уверенности организаций обрабатывающих производств | Индекс предпринимательской уверенности, Росстат, 2005-2008, месяц. |
| | Индекс предпринимательской уверенности по добыче полезных ископаемых | Индекс предпринимательской уверенности, Росстат, 2005-2008, месяц. |
| | Индекс предпринимательской уверенности организаций, обеспечивающих электрической энергией, газом и паром; кондиционированием воздуха | Индекс предпринимательской уверенности, Росстат, 2005-2008, месяц. |
| Реальный сектор | Среднеотраслевые цены | Индекс цен в отрасли, Росстат, 2005-2018, месяц. |

| | | |
|-------------------|--|---|
| | Стоимость труда | Среднемесячная реальная начисленная начисленная заработная плата, 2005-2018, месяц. |
| | Стоимость электроэнергии | Средние цены отпущенной электроэнергии промышленным предприятиям, 2005-2018, месяц. |
| | Объем государственных субсидий | Субсидии на про-во отраслей, Росстат, 2005-2018, месяц. |
| | Издержки транспортировки | Индекс тарифов на грузовые перевозки по всем видам транспорта, 2005-2018, месяц |
| | Доля квалифицированного труда в промышленности | Доля квалифицированного труда, Росстат, 2005-2018, годовые (неизменная для месяца) |
| | ВВП основных стран импортеров (Китай, Япония, Индонезия) | ВВП в текущих ценах, FRED, 2005-2018, квартальные |
| Финансовый сектор | Мировая стоимость нефти | Цена нефти марки Brent, Финам, 2005-2018, средняя за месяц. |
| | Денежная масса | Банк России, 2005-2018, месяц. |
| | Объем кредитов реальному сектору | Банк России, 2005-2018, месяц. |
| | Процентная ставка | Банк России, 2005-2018, месяц. |
| | Валютный курс | Банк России, 2005-2018, месяц. |
| | Фондовые индексы | Финам, Блумберг 2005-2018, месяц. |

Важно отметить, что предлагаемый набор факторов не является конечным и в процессе дальнейшего развития темы, предполагается его расширить. К примеру, потенциально к ожиданиям экономических агентов могут быть отнесены поисковые запросы. Существует ряд работ, в которых демонстрируется, что частотность поисковых запросов по определенным темам, относящимся к финансовым рынкам, политике, являются значимыми объясняемыми переменными для макроэкономических показателей, таких как индекс промышленного производства, инфляция, валютный курс [20, 21].

3.2 Описание алгоритма формирования отдельных переменных

Процесс предобработки данных в данном исследовании занимает достаточно большую часть и конечный результат весьма к нему чувствителен. Это связано, как с этапами обработки данных для определения поворотных точек и выявления лидирующих индикаторов, так и особенностями нейросетевого моделирования в процессе прогнозирования. Поэтому стоит особенно детально остановиться на том, какие шаги предпринимаются в процессе подготовки данных к использованию. Схематично процесс обработки данных представлен на схеме общего процесса построения композитного индекса (рисунок 6). Далее каждый блок в схеме будет разобран более подробно.

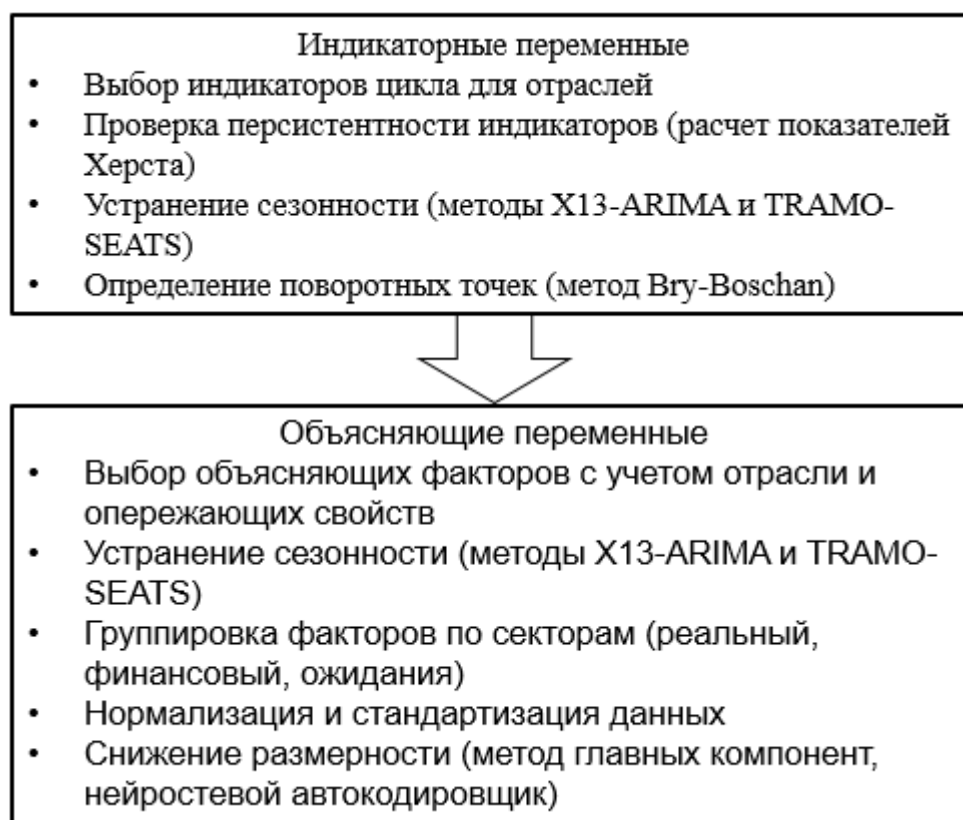


Рисунок 6 – Общая схема обработки данных и построения композитного индекса

Приступая к анализу собранных временных рядов, следуя подходу, описанному в работе С. Дробышевского [22], мы учитываем четыре типа факторов, под воздействием

которых могли сформироваться рассматриваемые данные: долговременные, сезонные, циклические (или конъюнктурные) и случайные. Для разложения ряда на тренд, сезонность и циклическую компоненту используются методы X13-ARIMA и TRAMO-SEATS, реализованные в статистическом пакете программной среды «R». Для того, чтобы сглаживание временных рядов было осуществлено корректно, предварительно удаляются выбросы в данных. Выбросы - это наблюдения в рядах компонентов, которые находятся за пределами нормального диапазона ожидаемых наблюдений. Для циклического анализа такие выбросы должны быть отфильтрованы в большинстве случаев, особенно когда они не связаны с переломными моментами в бизнес-цикле [8].

Далее, необходимо убедиться, действительно ли в формировании значений рассматриваемых рядов (в первую очередь совпадающих индикаторов – индексов производства выбранных отраслей, для которых предполагается построение прогнозных моделей) участвовали какие-либо факторы, помимо чисто случайных. При этом под «чисто случайными» понимаются лишь те случайные факторы, под воздействием которых генерируются последовательности взаимно не коррелированных и одинаково распределенных случайных величин, обладающих постоянными (не зависящими от времени) средними значениями и дисперсиями. Кроме того, мы проверяем индексы производства на персистентность. Персистентный процесс характеризуется долгосрочной памятью. Временные ряды с высокой персистентностью могут хорошо прогнозироваться моделями класса ARIMA или нейронными сетями с долгосрочной памятью. В работе К. Гусева [23] показано, что фильтрация временного ряда увеличивает его долгосрочную память. По этой причине проверка осуществляется уже на сглаженных рядах, с удаленной сезонностью. Мерой долгосрочной памяти может быть индекс Херста. Он выявляет накопление и наследование прошлой информации временных рядов. Если индекс Херста больше значения 0.5, то процесс считается персистентным [23].

На рисунке 7 продемонстрирован RS – анализ (анализ фрактальной структуры временных рядов) индекса производства Добычи топливно-энергетических полезных ископаемых, конечным результатом которого является индекс Херста. Показатель строится на цепном, очищенном от сезонности индексе производства (представлен на верхнем левом рисунке). Индексу Херста соответствует наклон прямой на нижнем правом графике, который в данном случае равен 0.497. Таким образом, о долгосрочной памяти индекса СА говорить нельзя, однако значение близко к пограничному.




Рисунок 7 – Расчет показателя Херста для индекса производства Добычи топливно-энергетических полезных ископаемых.

На рисунке 8 изображен RS – анализ для индекса производства Добычи полезных ископаемых, кроме топливно-энергетических. Показатель Херста для индекса равен 0.502, что считается достаточным для того, чтоб процесс считался персистентным. Это говорит о том, что временной ряд обладает долгосрочной памятью и добавление лагированного индекса в пул объясняющих переменных, теоретически, может улучшить прогноз модели.

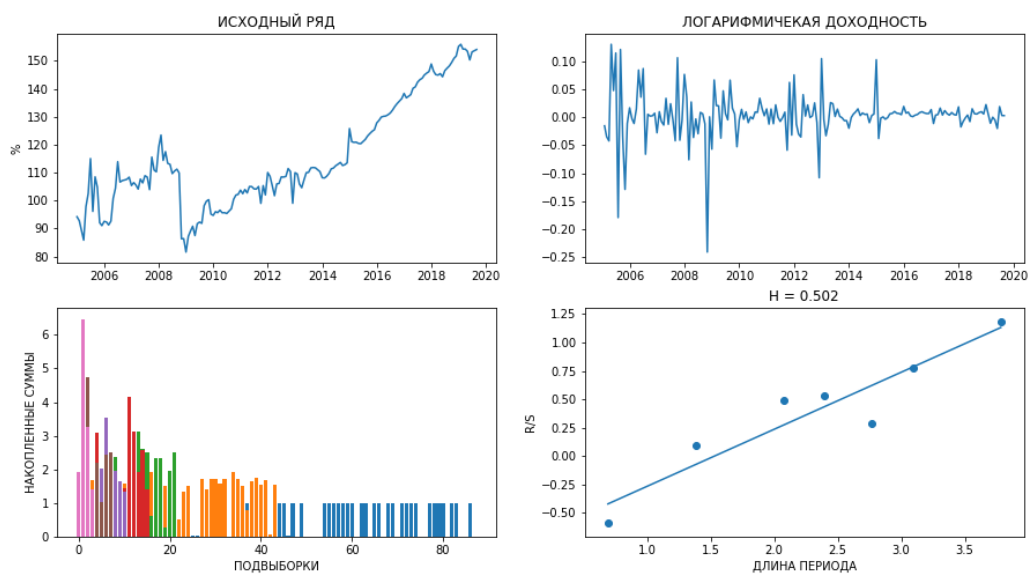


Рисунок 8— Расчет показателя Херста для индекса Добычи полезных ископаемых, кроме топливно-энергетических.

На рисунке 9 изображен RS – анализ для индекса Производства кокса, нефтепродуктов и ядерных материалов. Показатель Херста для индекса равен 0.731, что считается достаточным высоким значением для того, чтоб считать процесс персистентным. Использование лагированного индекса в качестве объясняющей переменной должно значительно улучшить прогностический характеристики модели.




Рисунок 9 – Расчет показателя Херста для индекса Производства кокса, нефтепродуктов и ядерных материалов.

На рисунке 10 изображен RS – анализ для индекса Металлургического производства и производства готовых металлических изделий. Показатель Херста для индекса равен 0.575, что считается достаточным значением для того, чтоб считать процесс персистентным. Использование лагированного индекса в качестве объясняющей переменной, возможно, позволит улучшить прогноз модели.

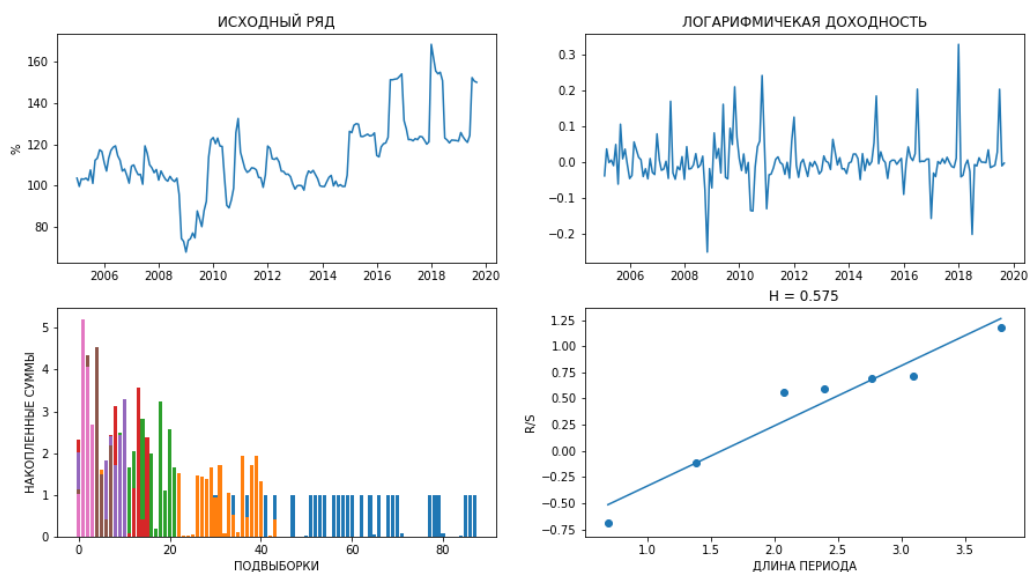


Рисунок 10 – Расчет показателя Херста для индекса Metallургического производства и производства готовых металлических изделий.

Однако стоит принять во внимание, что для точного определения показателя Херста ряд должен быть достаточно длинный.

Далее следует датировка поворотных точек, которая осуществляется для совпадающих индикаторов экономического цикла – четырех индексов производства. Поскольку собственная прогностическая модель относится к классу моделей машинного обучения с учителем, необходимо иметь правильно размеченные данные тестовой выборки. Датировка поворотных точек и есть процесс разметки данных для задачи классификации – когда мы определяем вероятность вхождения индикатора в рецессию в следующем периоде. В случае прогнозирования в уровнях, определение поворотных точек может осуществляться после получения прогнозных значений, однако для прогнозирования в уровнях требуется существенная переработка архитектуры прогнозной модели, что может быть перспективной темой, продолжающей данное исследование.

Алгоритм устроен таким образом, что позволяет избежать смещения поворотной точки относительно ее истинного положения вправо в отличие от поиска локальных максимумов и минимумов на очищенном от сезонности сглаженном ряде. Это возможно благодаря тому, что индекс сперва сглаживается с помощью четырех различных фильтров, а затем полученные ряды датируются независимо (при помощи поиска локальных максимумов и минимумов), после чего на менее сглаженных рядах остаются только точки, которые находятся в окрестностях точек на более сглаженных рядах. При этом на каждом этапе отбор должен соответствовать требованиям: пик чередуется с дном,

присутствуют ограничение на минимальную длительность фазы и ограничение на дисперсию. В свое время Брай и Бошан на основе американского опыта определили, что для месячных данных лучше всего подходит ограничение на фазу $K > 5$ месяцев (в то время как для квартальных $K > 2$). Для разграничения фаз цикла в выбранных индексах промышленного производства мы применили алгоритм с параметрами из работы Дубовского, Кофанова, а также использовали различные K для того, чтобы оценить стабильность полученных результатов.

В работу алгоритма Брая-Бошана на основе опыта Дубовского и Кофановы нами были заложены следующие критерии: пик должен чередоваться с дном, минимальная длина фазы – 5 месяцев; минимальная длина цикла (продолжительность) – 10 месяцев; глубина – в зависимости от дисперсии показателя, а также проведена верификация данных критериев. Данные ограничения необходимы для того, чтоб в процессе автоматического определения границ циклов, алгоритм не принимал за рецессию кратковременный (или сезонный) неглубокий спад в отрасли. Или напротив – за фазу роста период, где наблюдалась стагнация или непродолжительный восстановительный рост.

Для каждого ряда индекса производства, предварительно пересчитанного в цепной из месячных приростов, мы использовали четыре фильтра: скользящую среднюю, с параметром сглаживания, равным 3; скользящую среднюю, с параметром, равным 6; фильтр Ходрика-Прескота с параметром, равным 150 и сезонную корректировку по методу X13ARIMA.

Результаты определения поворотных точек для отрасли добыча топливно-энергетический полезных ископаемых приведены в таблице 5 и проиллюстрированы графически на рисунке 11.

Таблица 5 – Определение поворотных точек для отрасли добыча топливно-энергетический полезных ископаемых

| | Фаза | Начало | Конец | Дюрация | Уровень начала фазы | Уровень конца фазы | Амплитуда |
|---|----------|---------|---------|---------|---------------------------|--------------------------|-----------|
| 1 | Рост | <-> | 2007M1 | - | - | 108 | - |
| 2 | Рецессия | 2007M1 | 2009M3 | 26 | 108 | 105 | 3,3 |
| 3 | Рост | 2009M3 | 2012M2 | 35 | 105 | 115 | 10,5 |
| 4 | Рецессия | 2012M2 | 2012M10 | 8 | 115 | 111 | 4,1 |
| 5 | Рост | 2012M10 | 2013M7 | 9 | 111 | 114 | 2,9 |
| 6 | Рецессия | 2013M7 | 2013M12 | 5 | 114 | 113 | 1,3 |

| | | | | | | | |
|----|----------|---------|---------|----|-----|-----|-----|
| 7 | Рост | 2013М12 | 2014М12 | 12 | 113 | 116 | 3,1 |
| 8 | Рецессия | 2014М12 | 2016М1 | 13 | 116 | 111 | 4,9 |
| 9 | Рост | 2016М1 | 2016М12 | 11 | 111 | 113 | 1,6 |
| 10 | Рецессия | 2016М12 | 2018М1 | 13 | 113 | 108 | 4,3 |
| 11 | Рост | 2018М1 | 2019М3 | 14 | 108 | 111 | 2,8 |
| 12 | Рецессия | 2019М3 | <-> | - | 111 | - | - |

Рецессия 2007 – 2009 гг. наблюдается во всех отраслях и связана с мировым финансовым кризисом, приведшим к значительному падению условий торговли и оттоку капитала из России. Оба фактора привели к сокращению совокупного спроса и значительному падению производства и добычи полезных ископаемых.

В частности, согласно результатам, отрасль добычи топливно-энергетических полезных ископаемых находилась в рецессии с декабря 2014 года по январь 2016 (- 4.8% за период). Точку входа отрасли в рецессию озаменовали: «черный понедельник» с обвалом курса рубля на бирже, сохранение квот ОПЕК на производство нефти и непрозрачная сделка с облигациями Роснефти, произошедшие в конце 2014 года. Выход из рецессии был связан с начавшимся ростом цен на нефть (+ 2.1% за период с января 2016 по декабрь 2016). В декабре 2016 отрасль снова вошла в рецессию на 13 месяцев (- 2.9% за период), что было связано с волатильностью цен на энергоресурсы. Затем последовал восстановительный рост, закончившийся в марте 2019 (+ 4.8% за период), что было связано с временной заморозкой цен на внутреннем рынке нефтепродуктов одновременно с начавшимся в январе налоговым маневром, а также инцидентом с загрязненной нефтью в нефтепроводе Дружба».




Рисунок 11 – Фазы цикла отрасли добычи топливно-энергетических полезных ископаемых.

Примечание: белому фону соответствуют периоды роста; серому фону – периоды рецессии.

Результаты определения поворотных точек для отрасли «Добыча полезных ископаемых, кроме топливно-энергетических» приведены в таблице 6 и проиллюстрированы графически на рисунке 12.

Таблица 6 – Определение поворотных точек для отрасли добыча полезных ископаемых, кроме топливно-энергетических

| | Фаза | Начало | Конец | Длительность | Уровень начала фазы | Уровень конца фазы | Амплитуда |
|----|----------|--------|--------|--------------|---------------------------|--------------------------|-----------|
| 1 | Рост | <-> | 2005M7 | - | - | 115 | - |
| 2 | Рецессия | 2005M7 | 2007M9 | 26 | 115 | 104 | 11,1 |
| 3 | Рост | 2007M9 | 2008M2 | 5 | 104 | 123 | 19,5 |
| 4 | Рецессия | 2008M2 | 2009M1 | 11 | 123 | 82 | 41,8 |
| 5 | Рост | 2009M1 | 2013M9 | 56 | 82 | 112 | 30,2 |
| 6 | Рецессия | 2013M9 | 2014M2 | 5 | 112 | 108 | 3,7 |
| 7 | Рост | 2014M2 | 2015M1 | 11 | 108 | 126 | 17,7 |
| 8 | Рецессия | 2015M1 | 2015M6 | 5 | 126 | 120 | 5,4 |
| 9 | Рост | 2015M6 | 2018M1 | 31 | 120 | 149 | 28,5 |
| 10 | Рецессия | 2018M1 | 2018M6 | 5 | 149 | 144 | 4,6 |
| 11 | Рост | 2018M6 | 2019M2 | 8 | 144 | 156 | 11,6 |

| | | | | | | | |
|----|----------|--------|-----|---|-----|---|---|
| 12 | Рецессия | 2019M2 | <-> | - | 156 | - | - |
|----|----------|--------|-----|---|-----|---|---|

Отрасль рудных полезных ископаемых, согласно проведенным расчетам, находилась в рецессии с января 2015 по июнь 2015 (- 7.7 % за период), а затем с января 2018 по июнь 2018 (- 5.18% за период), что можно объяснить снижением мировых цен на железную руду и ухудшением финансового положения основных компаний отрасли.




Рисунок 12 – Фазы цикла отрасли добыча полезных ископаемых, кроме топливно-энергетических. Примечание: белому фону соответствуют периоды роста; серому фону – периоды рецессии.

Результаты определения поворотных точек для отрасли «Производство кокса, нефтепродуктов и ядерных материалов» приведены в таблице 7 и проиллюстрированы графически на рисунке 13.

Таблица 7 – Фазы экономического цикла для отрасли производство кокса, нефтепродуктов и ядерных материалов

| | Фаза | Начало | Конец | Дюрация | Уровень начала фазы | Уровень конца фазы | Амплитуда |
|---|----------|--------|--------|---------|---------------------------|--------------------------|-----------|
| 1 | Рост | <-> | 2007M4 | - | - | 115 | - |
| 2 | Рецессия | 2007M4 | 2007M9 | 5 | 115 | 114 | 0,7 |
| 3 | Рост | 2007M9 | 2008M8 | 11 | 114 | 119 | 5 |
| 4 | Рецессия | 2008M8 | 2009M1 | 5 | 119 | 114 | 4,5 |

| | | | | | | | |
|----|----------|---------|---------|----|-----|-----|------|
| 5 | Рост | 2009M1 | 2015M7 | 78 | 114 | 150 | 35,2 |
| 6 | Рецессия | 2015M7 | 2016M3 | 8 | 150 | 140 | 9,2 |
| 7 | Рост | 2016M3 | 2016M11 | 8 | 140 | 144 | 3,2 |
| 8 | Рецессия | 2016M11 | 2017M3 | 4 | 144 | 143 | 0,7 |
| 9 | Рост | 2017M3 | 2019M3 | 24 | 143 | 149 | 6,1 |
| 10 | Рецессия | 2019M3 | <-> | - | 149 | - | - |

Производство кокса, нефтепродуктов и ядерных материалов находилось в рецессии с июля 2015 по март 2016 (- 6.7% за период), а затем с ноября 2016 по март 2017 (- 4.2% за период). Производство кокса является важной составляющей промышленного комплекса, поэтому предшествующая рецессия в металлургическом производстве с апреля 2015 года по февраль 2016 (- 11.4% за период) частично ее обуславливает.




Рисунок 13 – Фазы цикла отрасли производство кокса, нефтепродуктов и ядерных материалов. Примечание: белому фону соответствуют периоды роста; серому фону – периоды рецессии.

Результаты определения поворотных точек для отрасли «Металлургическое производство и производство готовых металлических изделий» приведены в таблице 8 и проиллюстрированы графически на рисунке 14.

Таблица 8 – Фазы цикла для отрасли металлургическое производство и производство готовых металлических изделий

| | Фаза | Начало | Конец | Дюрация | Уровень начала фазы | Уровень конца фазы | Амплитуда |
|----|----------|---------|---------|---------|---------------------------|--------------------------|-----------|
| 1 | Рецессия | <-> | 2005M8 | - | - | 101 | - |
| 2 | Рост | 2005M8 | 2006M6 | 10 | 101 | 119 | 18,2 |
| 3 | Рецессия | 2006M6 | 2009M1 | 31 | 119 | 68 | 51,4 |
| 4 | Рост | 2009M1 | 2010M12 | 23 | 68 | 133 | 64,7 |
| 5 | Рецессия | 2010M12 | 2013M5 | 29 | 133 | 98 | 34,7 |
| 6 | Рост | 2013M5 | 2015M4 | 23 | 98 | 130 | 32,2 |
| 7 | Рецессия | 2015M4 | 2016M2 | 10 | 130 | 114 | 16,1 |
| 8 | Рост | 2016M2 | 2018M1 | 23 | 114 | 168 | 54,5 |
| 9 | Рецессия | 2018M1 | 2018M9 | 8 | 168 | 121 | 47,7 |
| 10 | Рост | 2018M9 | <-> | - | 121 | - | - |

Кризис в металлургической отрасли 2015 г. связан, во многом, с резким падением экспорта, вызванным введением против РФ заградительных пошлин и точечных санкций, а также с низким внутренним спросом. В начале 2018 очередной рост пошлин (одновременно на американском и европейском рынках) привел металлургическую отрасль к очередной рецессии, что и зафиксировал алгоритм (с января 2018 по сентябрь 2018 - 7.5% за период).




Рисунок 14 – Фазы цикла для отрасли металлургическое производство и производство готовых металлических изделий. Примечание: белому фону соответствуют периоды роста; серому фону – периоды рецессии.

В таблице 9 приведены для сравнения фазы цикла, определенные отечественными исследователями для индекса промышленного производства и общего экономического цикла.

Таблица 9 – Результаты датировки индекса промышленного производства и общего экономического цикла в работах отечественных исследователей

| | Пик | Дно | Пик | Дно | Пик |
|---------------------|--------|--------|---------|--------|--------|
| ИПП (Смирнов) | Фев.08 | Янв.09 | - | - | Дек.14 |
| Эк.цикл (Смирнов) | Июн.08 | Май.09 | - | - | Дек.14 |
| ИПП (Кофанов) | Мар.08 | Фев.09 | Окт.12 | Мар.13 | Апр.14 |
| Обр. пром (Кофанов) | Янв.08 | Апр.09 | Сент.12 | Мар.13 | Май.14 |

Источник: Кофанов, Смирнов [18, 6]

Полученные в результате применения алгоритма поворотные точки на пересекающейся части выборки для отраслей из раздела добычи полезных ископаемых оказываются близки к поворотным точкам ИПП Дубовского; для отраслей из раздела обрабатывающие производства близки к поворотным точкам индекса обрабатывающих производств.

Для последней наблюдаемой точки алгоритм может неправильно оценивать вероятность нахождения в рецессии (из-за сезонного сглаживания рядов), поэтому прогнозная модель используется в качестве наукаста и прогноза на $t+1$ от спрогнозированной точки.

Следующий этап предполагает прогнозирование вероятности рецессии в выбранных отраслях при помощи нейросетевых моделей. Нейронная сеть, в силу особенностей используемых функций активации в процессе обучения, чувствительна к масштабу данных. Естественной практикой при работе с нейронными сетями является масштабирование и нормализация данных. Процесс нормализации состоит в вычитании из отфильтрованных наблюдений среднего значения ряда и делением его на стандартное отклонение.

В силу того, что отечественная макростатистика располагает весьма ограниченным временным горизонтом, то при оценке моделей возникает необходимость «экономить» степени свободы. Для этой цели мы использовали снижение размерности данных вплоть до одной главной компоненты для каждой из трех категорий показателей. Для оптимального сжатия данных использовался нелинейный метод на основе нейросетевого автокодировщика, который по своей сути является аналогом ядерного метода главных компонент, но в отличие от него не требует априорного знания вида функции отображения.

Нейросетевой автокодировщик для снижения размерности данных.

Для решения вышеописанной задачи – снижения размерности входных данных нами на языке Python 3.6 был реализован нейросетевой автокодировщик. Автокодировщик представляет собой полносвязную нейронную сеть с архитектурой «бутылочное горлышко», где на вход и на выход подаются одни и те же данные. Условный пример архитектуры представлен на рисунке 15. В каждый нейрон на вход подается вектор, соответствующий одному фактору. Количество нейронов на первом слое равняется количеству имеющихся объясняющих факторов. На двух последующих слоях количество нейронов уменьшается. Количество нейронов в середине сети равно количеству главных компонент, которые предполагается выделить из набора имеющихся данных. Эта часть

нейронной сети называют кодировщиком, поскольку данные, протекая по такой сети, искусственно сжимаются. Затем сеть зеркально разворачивается, т.е. к слою «бутылочное горлышко» добавляются слои декодировщика, который восстанавливает размерность данных до исходных. В процессе минимизации ошибки веса сети будут подбираться таким образом, чтоб через узкий проход нейронной сети протекало максимум информации для восстановления данных к первоначальному виду, что обеспечит оптимальное снижение размерности. Наличие промежуточных внутренних слоев позволяет сети находить сложные зависимости между данными, в том числе и нелинейные. После обучения нейронной сети стандартным методом обратного распространения ошибки, от нее отрезается слой декодировщика, и используется только слой кодировщика. Его выход представляет собой главные компоненты данных.




Рисунок 15 – Условный пример архитектуры нейросетевого автокодировщика.

Применительно к решаемой задаче снижения размерности – количество входных нейронов (как и выходных) равняется количеству факторов, отнесенных к соответствующей группе: реального сектора и финансового сектора. Таким образом, строится два индивидуальных автокодировщика для каждой изучаемой отрасли. К примеру, для отрасли Добычи полезных ископаемых размерность данных, отражающих реальный сектор равняется девяти, поскольку туда входят следующие факторы: среднеотраслевые цены; стоимость труда; стоимость электроэнергии; объем государственных субсидий; издержки транспортировки; доля квалифицированного труда в промышленности; ВВП основных стран импортеров (Китай, Япония, Индонезия).

Следовательно, для данной группы факторов количество нейронов на первом слое будет равняться девяти, на втором слое пяти (в качестве нелинейной функции активации используется гиперболический тангенс), на третьем слое «бутылочного горлышка» - одному с линейной функцией активации. Декодировщик имеет симметрично-зеркальную структуру. Кроме того, между слоями используется «дропаут» с вероятностью 0.5, который выполняет регуляризационную функцию в нейронных сетях. В качестве оптимизатора используется «Adamax», сеть обучается на 300 эпохах. На рисунке 16 приведен результат работы автокодировщика для выделения главных компонент двух групп факторов.




Рисунок 16 – Выделенные две главные компоненты нейросетевым автокодировщиком из групп факторов: реальный сектор и финансовый сектор.

Для сравнения результативности работы автокодировщика мы так же применяли к исходным данным стандартный метод главных компонент, реализованный в пакете «Sklearn», функция «PCA». Его результаты снижения размерности до двух факторов приведены на рисунке 17.




Рисунок 17 – Выделенные две главных компоненты линейным методом главных компонент из групп факторов: реальный сектор и финансовый сектор.

Как можно видеть два алгоритма несколько схожим образом выделяют две главных компоненты. Важным является тот факт, что в обоих случаях корреляция между двумя главными компонентами близка к нулю. В случае использования в качестве прогнозной модели логистической регрессии подобный факт избавляет от возможной проблемы мультиколлинеарности и смещенных оценок. В случае нейросетевых прогнозных моделей корреляция между факторами не имеет значения и не отражается на эффективности процесса обучения. Предварительные расчеты при построении прогнозов с использованием логистической регрессии с различными подходами к снижению размерности в целом не выявили наиболее предпочтительного метода. Однако финальные оценки и прогнозы мы будем демонстрировать с учетом применения собственной модели снижения размерности.

В данной главе содержится описание используемых в собственном эмпирическом исследовании данных, а также приводятся логика и результаты необходимой предобработки. Этапы предобработки данных включали в себя: построение индикатора рецессии отрасли (для чего проводилось определение фаз экономического цикла с применением алгоритмической процедуры Брая-Бошана); проверку на персистентность индексов производства; формирование окончательного списка объясняющих факторов

(исходя из их совпадающих и опережающих свойств, стандартизация и масштабирование объясняющих факторов; применение методов снижения размерности.

4. Моделирование, верифицирование полученных результатов

Для моделирования экономического цикла в каждой выбранной отрасли строится бинарный индикатор, который присваивает значение 0 от пика до впадины, 1 в противном случае, чтобы получить соответствующую информацию о цикле, извлеченную с помощью алгоритма Брая-Бошана. Для датировки цикла выбор был сделан в пользу алгоритма Брая-Бошана, поскольку альтернативные алгоритмические процедуры на российских данных показали худший результат, в частности в работе Смирнова [18] модель с марковскими переключениями сгенерировала множество ложных поворотных точек.

Отобранные факторы для каждой отрасли были сгруппированы в три группы: переменные реального сектора, финансового и ожидания рынка. Поскольку в условиях короткой временной макроэкономической статистики возникает необходимость экономии степеней свободы, к каждой группе в отдельности изначально предполагалось применять алгоритм снижения размерности (нейросетевой автокодировщик), описанный в предыдущей главе. Однако предварительное тестирование показало, что агрегацию имеющегося пула данных предпочтительнее провести до двух главных компонент, в противном случае в сверточной нейронной сети возникает чрезмерно большое количество параметров, которые необходимо обучить, в результате чего модель переобучается на тренировочной выборке, но показывает низкие прогностические качества на тестовой выборке. Для снижения размерности данных до двух главных компонент факторы, характеризующие ожидания экономических агентов (Индекс предпринимательской уверенности организаций обрабатывающих производств; индекс предпринимательской уверенности по добыче полезных ископаемых и прочие) были отнесены к финансовому сектору. В результате автокодировщик, обученный на объединенном пуле данных финансового сектора и ожиданий экономических агентов и отдельно на данных реального сектора, снижает размерность исходного набора данных до двух главных компонент для каждой изучаемой отрасли. Обозначенные две главные компоненты совместно с уровнями самого индекса производства, на основе которого построена бинарная объясняемая переменная, используются в качестве объясняющих факторов в предлагаемых к сравнению прогностных моделях с месячным лагом: полносвязной нейронной сети, сверточной нейронной сети и логистической регрессией.

4.1 Обучение и тонкая настройка нейросетевой модели

Для сравнения прогностических характеристик основной предполагаемой прогностной модели – условной сверточной нейронной сети, строятся дополнительно: условная полносвязная нейронная сеть и условная логистическая регрессия. В качестве

метрик мы приводим значения точности, полноты классификации, а также их гармонического среднего (f-score). Для сопоставимости результатов все три модели будут обучаться на одинаковых данных с аналогичной для каждой модели процедурой предобработки данных: очищение от сезонности, стандартизация и применение процедуры снижения размерности для выделения главных компонент. Условная модель предполагает использование в качестве объясняющих переменных главных компонент, выделенных на предыдущем этапе.

Построение нейронных сетей осуществлялось в среде программирования Python 3.6 с использованием следующих пакетов: «Keras» версии 2.0.9 (используется, как основной инструмент построения нейронных сетей); «tensorflow» версии 1.13.1 (используется в качестве вычислительной основы для предыдущего пакета, ускоряя и упрощая операции с матрицами и тензорами данных; внутри этого пакета реализован весь процесс обучения нейронной сети с использованием метода обратного распространения ошибки и графового метода расчета частных производных); «matplotlib» версии 3.0.0 (предназначен для визуализации этапов обучения нейронной сети и метрик качества прогноза); «numpy» версии 1.15.2 (пакет предназначен для обработки данных и работы с векторами); «pandas» версии 0.23.4 (предназначен для обработки, визуализации данных, представления результатов расчетов в табличном виде, удобном для загрузки из среды программирования); «scikit-learn» версии 0.20.1 (пакет предназначен для построения эконометрических моделей, используется для построения прогнозной неинтерпретируемой логистической модели, а также содержит готовые функции предобработки данных, к примеру, разбиения выборки на обучающую и валидационную, а так же для расчета метрик обучения); «statsmodels» версии 0.9.0 (пакет используется для оценки эконометрических моделей, расчетов доверительных интервалов, стандартных ошибок коэффициентов и прочих статистик, используется для построения интерпретируемой логистической модели).

4.1.1

Моделирование состояния отраслей при помощи полносвязной нейронной сети.

На рисунке 18 схематично изображена схема условной полносвязной нейронной сети.

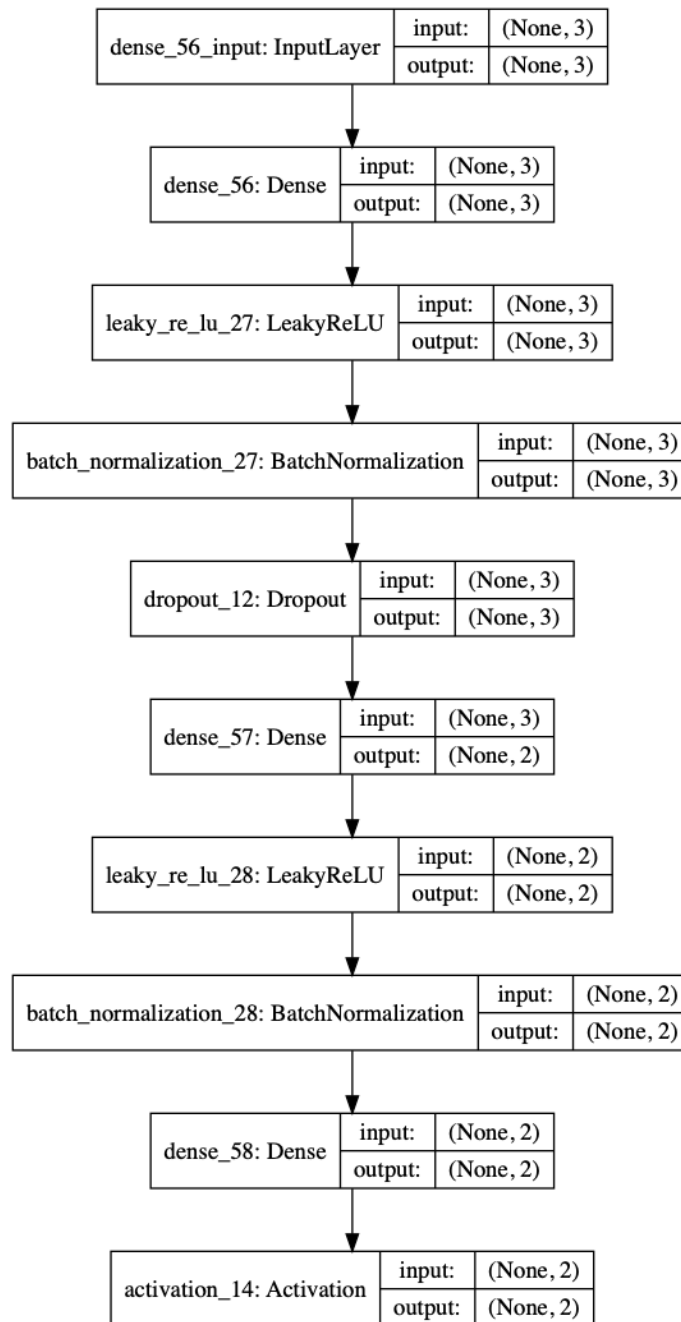


Рисунок 18 – Архитектура условной полносвязной нейронной сети.

На первом слое сети используется три нейрона с активационной функцией «LeakyReLU». Количество нейронов на первом слое обусловлено количеством входных данных: двух главных компонент из набора объясняющих переменных, отражающих тенденции в секторе реальной экономики и в реальном секторе. Таким образом, данные на вход нейронной сети подаются без учета временной структуры. Без учета нелинейности в нейронах, такое устройство сети соответствует трем соединенным между собой линейным регрессиям, каждая из которых использует один и тот же набор входных данных. Однако ошибка каждой такой регрессии рассчитывается исходя из различных объясняемых переменных, которые рассчитываются в результате проброса градиентов методом

обратного распространения ошибки. Кроме того, внутри каждого нейрона используется «activity_regularizer» еще до применения нелинейно функции активации. В аналогии с классической эконометрикой эта операция выполняет регуляризацию параметров линейной комбинации входных данных. В некоторый преобраз ошибки, рассчитываемый на выходе из нейрона в процессе обратного распространения, добавляется штраф на параметры нейрона. Это частично позволяет бороться с проблемой переобучения и в том числе, с описанной в теоретическом блоке - проблемой взрыва градиентов. Следующим блоком сети является батч-нормализация. Этот блок обрабатывает выходы из нейронов первого слоя, нормализуя преобразованные внутри нейронов входные данные с учетом уже примененной функции активации. Это необходимо для того, чтоб градиенты были более плавные и в процессе обучения не происходило искусственного завышения или занижения значимости определенного фактора (из-за разницы в уровнях рядов) или, что в случае выхода из первого слоя, одной из протекающих линейно взвешенных, но нелинейной из-за примененной функции активации, некоторой комбинации факторов. Следующим блоком сети является «дропаут», который представляет собой также элемент регуляризации. Данный функциональный блок располагается между слоями сети: первым, состоящим из трех нейронов и вторым, состоящим из двух нейронов, и случайным образом обрывает некоторые связи, т.е. обнуляет веса, которых между первым и вторым слоем восемь: выходы из трех нейронов первого слоя соединены «каждый с каждым» с входами второго слоя, состоящего из двух нейронов. Соответственно первый нейрон второго слоя принимает линейную комбинацию от трех нейронов предыдущего слоя, для чего ему требуется три параметра – весовых коэффициента и один параметр смещения (часто называют нейроном смещения, по сути является обучаемой константой смещения). Аналогично, второй нейрон второго слоя принимает взвешенную линейную комбинацию от трех нейронов предыдущего слоя, для чего ему также требуется три параметра и один нейрон смещения. Итого, получается, восемь параметров, которые необходимо обучить в процессе градиентного спуска, составляющего основу процесса обратного распространения ошибки на втором слое. Вторым скрой является скрытым, весовые параметры этого слоя уже являются неидентифицируемыми, поскольку взвешивают уже взвешенные линейные комбинации факторов, к тому же, пропущенные через нелинейные функции активации. Но именно второй слой позволяет отображать данные в такое подпространство, где в случае нелинейности данных, классификационный алгоритм сумеет построить такие гиперплоскости, которые будут разделять существующие классы. В случае решаемой задачи – это фазы роста и рецессии. Нейроны второго слоя нейронной

сети также содержат «activity_regularizer» на параметры и функцию активации «LeakyReLU». За вторым слоем снова следует батч-нормализация, которая позволяет сглаживать изменение градиента. Затем два выхода из нейронов второго слоя попадают на вход последнему слою сети, который состоит из одного нейрона с логистической функцией активации, что позволяет преобразованные данные на предыдущих этапах нейронной сети преобразовать в вероятности, соответствующие фазе роста и фазе рецессии. Таким образом вся нейронная сеть сводится к простой логистической регрессии, которая принимает на вход два фактора, а в качестве объясняемой переменной – использует бинарное представление индекса производства, полученного на этапе применения алгоритма Брая-Бошана. Объясняющие факторы, в свою очередь, являются сложной нелинейной комбинацией исходных факторов. Невозможность «отрезать» последний слой от нейронной сети и оценивать его, как обычную логистическую регрессию, заключается в необходимости одновременного расчета всех параметров сети, что происходит на каждой итерации алгоритма обратного распространения ошибки. Обучается сеть в результате минимизации кроссэнтропии, специальной функции, позволяющей измерить схожесть двух дискретных распределений, но при этом являющейся непрерывной, от которой можно считать частные производные.

Во всей нейронной сети веса инициализируются случайным образом из нормального распределения с параметрами математического ожидания ноль и единичной дисперсией. В процессе обучения мы фактически используем не стохастический, а пакетный градиентный спуск, что связано с небольшим объемом данных и отсутствием необходимости сокращать время расчетов. Это означает, что направление градиента и пересчет весов определяется на основе расчета частных производных по всей тестовой выборке, без разбиения ее на мини-батчи. Для минимизации функции ошибки используется Adam с параметрами: скорость обучения $\text{learning rate} = 0.001$, $\text{beta 1} = 0.9$, $\text{beta 2} = 0.999$. Для обучения используется 150 эпох, количество которых подобрано в процессе эмпирических расчетов. Приблизительно на таком количестве эпох ошибка модели перестает уменьшаться и выходит на плато независимо от первоначальной инициализации весов. Общее количество параметров в модели равняется 46, 36 из которых являются обучаемыми, а 10 необучаемыми. Отношение количества наблюдений к количеству оцениваемых параметров в данной архитектуре сети равняется 9,68, т.е. на один параметр приходится около 10 наблюдений, что считается в литературе приемлемым.

В таблице 10 приведены результаты применения уже обученной нейронной сети к тестовым (валидационным) данным. Валидационная выборка для всех отраслей включает в себя период с января 2015 года по сентябрь 2019. При этом в соответствии с разделением:

1. СА на обучающей выборке содержится 90 периодов роста и 31 период рецессии; на тестовой выборке содержит 17 периодов роста и 30 периодов рецессии.
2. СВ на обучающей выборке 78 периодов роста, 43 периода рецессии; на тестовой выборке 37 периодов роста и 10 периодов рецессии;
3. DF на обучающей выборке содержится 111 периодов роста и 10 периодов рецессии; на тестовой выборке 35 периодов роста, 12 периодов рецессии;
4. DJ на обучающей выборке содержится 54 периода роста и 67 периодов рецессии; на тестовой выборке содержит 29 периодов роста и 18 периодов рецессии.

Как можно видеть по индексам СВ, DF классы в значительной степени не сбалансированы. Для улучшения качества прогнозов на несбалансированных выборках, как правило используется оптимизация метрики f -score – среднее гармоническое между точностью и полнотой классификации относительно класса, в отношении которого ошибка первого рода менее предпочтительна, что позволяет оптимальным образом подобрать порог отсечения вероятности при определении моделью метки класса. Для трех отраслей (СВ, DF, DJ) модель хуже предсказывает рецессию, что связано, как с несбалансированными по классам (рост, рецессия) обучающими и тестовыми выборками, так и с неоптимальным выбором порога интерпретации вероятности. Для отрасли СА при определении фаз роста модель верно определила лишь порядка 50% периодов; для отрасли СВ были верно предсказаны только около 30% фаз рецессии. В остальном результаты более приемлемые. Для отрасли DF сеть определяет правильно 56% рецессий и 72% периодов роста. Для отрасли DJ соответственно 55% рецессий и 63% роста.

4.2 Верификация и валидация полученных результатов

Нами будет использована несколько иная методология подбора оптимального порога, основанная на пересечении метрик точности и полноты, которая продемонстрировала лучший результат, чем оптимизация f -score на имеющихся данных.

Качество предсказаний нейронной сетью измеряется при помощи двух метрик: точности и полноты классификации. При этом обе метрики считаются независимо для каждой гипотезы: в данном случае нулевая гипотеза - рецессия; альтернативная – рост. Точность классификации для рецессии – это доля верно предсказанных периодов рецессии среди всех образцов тестовой выборки, отнесенных классификатором к

рецессии. Точность классификации для альтернативной гипотезы – это доля верно предсказанных периодов роста среди всех образцов тестовой выборки, отнесенных классификатором к росту. Полнота классификации для рецессии – это доля верно предсказанных периодов рецессии среди периодов рецессии, наблюдаемых в действительности. Полнота классификации для роста – это доля верно предсказанных периодов роста среди всех наблюдавшихся в действительности периодов роста. Кроме того, для удобства сравнения полученных результатов между различными моделями, мы считаем средние гармонические между точностью и полнотой для каждого класса. Данный показатель известен в литературе, как «f-score» метрика.

Таблица 10 – Результаты применения полносвязной условной нейронной сети к тестовой выборке

| Индекс | Точность | | Полнота | | Среднее гармоническое для H0 | Среднее гармоническое для H1 |
|--------|------------------|------------------|-------------------|-------------------|------------------------------|------------------------------|
| | PrH ₀ | PrH ₁ | RecH ₀ | RecH ₁ | | |
| CA | 0,65 | 0,37 | 0,5 | 0,53 | 0,57 | 0,44 |
| CB | 0,17 | 0,72 | 0,5 | 0,35 | 0,25 | 0,47 |
| DF | 0,55 | 0,96 | 0,92 | 0,74 | 0,69 | 0,84 |
| DJ | 0,35 | 0,58 | 0,44 | 0,48 | 0,39 | 0,53 |

4.1.2

Моделирование состояния отраслей при помощи сверточной нейронной сети.

В основе, предлагаемой сверточной нейронной сети находится архитектура «WaveNet» [24], разработанная для анализа и прогнозирования звукового сигнала. Данная архитектура уже была адаптирована для анализа временных рядов и применялась при прогнозировании фондового рынка [25].

В силу того, что сверточная архитектура сети, как правило применяется при работе с изображениями, входные данные должны быть специальным образом структурированы. При этом структура данных также несет в себе определенный смысл и влияет на конечный результат. Одним обучающим образцом сверточной нейронной сети является пиксельное изображение, имеющее двухмерную размерность. В случае временных рядов аналогом пиксельного изображения, то есть одним обучающим образцом, выступает временное окно объясняющих факторов, имеющее также двумерную размерность: аналогом пикселей, вытянутых по горизонтали выступает вектор объясняющих

переменных в один момент времени; аналогом пикселей, расположенных вдоль оси ординат, выступает вектор данных, представляющий изменение определенного фактора во времени. Скользящее окно, на котором обучается нейронная сеть, в нашем случае, равняется двум кварталам, что объясняется сенсорным правилом NBER США (если происходит снижение уровня экономической активности на протяжении двух кварталов, то в экономике признается рецессия). Аналогичное правило заложено в алгоритмическую процедуру определения поворотных точек, использованную нами на предыдущих этапах исследования, для построения бинарной объясняемой переменной. Устройство архитектуры нейронной сети отражает рисунок 19.

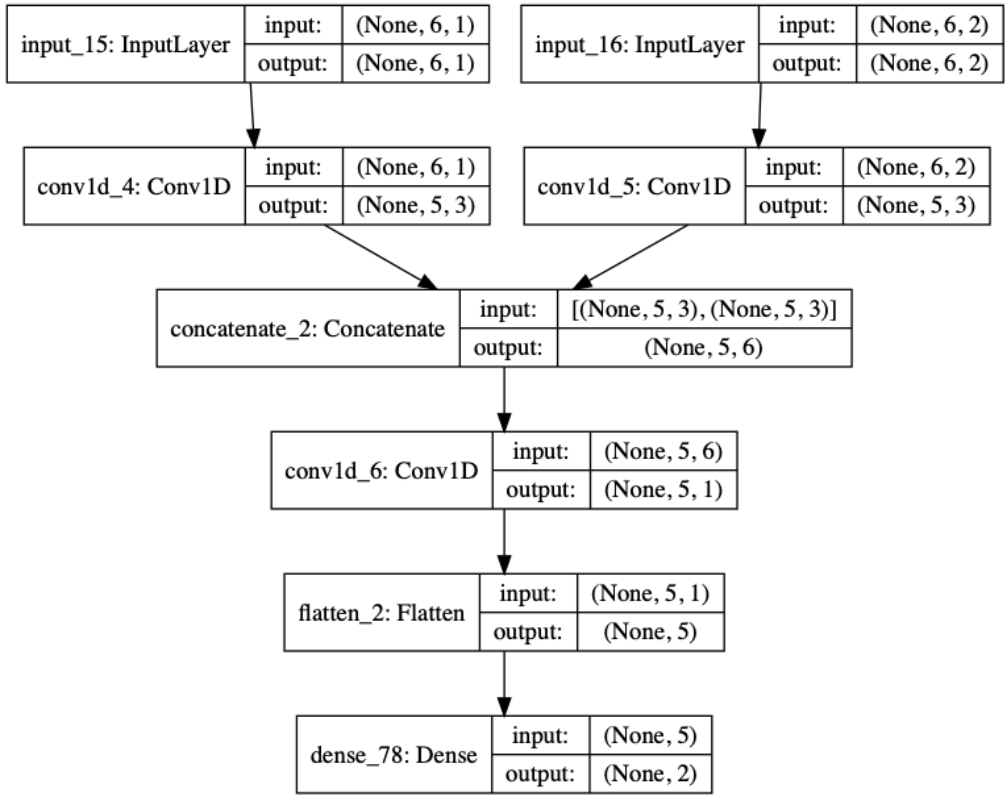


Рисунок 19 – Архитектура условной сверточной нейронной сети.

Конструкция сети представляет собой стек из двух независимых сверточных нейронных сетей: первая сеть (правая ветвь рисунка) предназначена для анализа лагированных значений выделенных двух главных компонент. Размерность входных данных (None, 6, 2) означает размерность одного обучающего образца. Первое значение не зависит от архитектуры нейронной сети и обозначает количество учебных образцов. В нашем случае на обучающей выборке это значение равно 167 и на тестовой выборке 47. Второй параметр – это и есть скользящее окно, равное 6 месяцам (двум кварталам), третий параметр – это количество факторов (в нашем случае 2 – число главных компонент). В

параллельной ветке (левая ветвь рисунка) происходит анализ лагированных значений индекса производства в уровнях, на основе которого были размечены фазы роста и рецессии отрасли и получен бинарный ряд, использующийся в качестве выходных данных нейронной сети. Индекс в уровнях с лагом в один месяц и бинарный ряд состояния отрасли были структурированы аналогичным образом с применением скользящего окна в два квартала. Необходимость стека из двух сетей связана с высокой персистентностью индексов. Временные ряды с высокой персистентностью (имеющие долгосрочную память) хорошо прогнозируются безусловными моделями класса ARIMA. Наличие в архитектуре сети ветви, где происходит одномерная свертка только по ряду фактически целевой переменной, позволяет искать закономерности в самом временном (фактически строить нелинейную ARIMA-модель). Вторая сеть в стеке отвечает за обусловленность прогноза и позволяет модели использовать дополнительные, экзогенные факторы при построении прогноза. В каждой ветви сети на первом уровне мы используем по три фильтра с ядром равным двум. В качестве функции активации в ядре используется «ReLu» и «L2» регуляризация, которая не дает в процессе обучения завышать определенные параметры. Фильтры первого уровня позволяют сети изучить временную структуру, а в случае двух главных компонент – еще и одновременно уловить взаимосвязи между ними в пространстве.

В результате работы трех фильтров каждой ветви сети получаются две матрицы одинаковой размерности (none, 5, 3), где первая размерность отвечает за количество учебных образцов, вторая размерность, равная пяти отражает снижение размерности учебного образца (окна) на единицу после прохождения по нему фильтра с ядром два и третья размерность означает, что у сети имеется по три представления исходных временных рядов после применения процедуры свертки. Одинаковая размерность данных на выходе из двух ветвей сети позволяет провести их конкатенацию: присоединение к одной матрице второй с сохранением оси времени. После этого к полученной матрице применяется свертка 1×1 , которая позволяет изучить нелинейные отношения между рядами, а точнее уже их некоторыми представлениями. На данном этапе мы используем один фильтр. Единичная свертка, соответственно, имеет ядро, равное единице, функцию активации «ReLu» и «L2» регуляризацию. Затем выход из сверточного слоя разворачивается в полносвязный слой и попадает на вход последнему слою, который представляет собой один нейрон с логистической функцией активации. Последний слой модели не отличается от аналогичного в полносвязной нейронной сети и позволяет решать задачу классификации – определения фаз экономического цикла. В качестве

функции ошибки используется стандартная кросс-энтропия, используется оптимизатор Adam с параметрами: скорость обучения learning rate = 0.001, beta 1 = 0.9, beta 2 = 0.999. В процессе обучения использовались 150 эпох, количество которых подобрано эмпирически исходя из поведения графиков значений ошибок и точности классификации на обучающей и валидационной выборках.

В оригинальной работе с описанием архитектуры «Wave_Net» [26] , взятой за основу, используется специальный элемент, позволяющий избежать исчезновения/взрыва градиентов при обучении нейронной сети - пропуск данных. С выходом на каждом слое складывается его же вход, что визуально можно представить, как петли от входа. В случае, если слой в целом не нужен сети, то его параметры обнуляются или частично обнуляются в процессе обучения. На качество и скорость обучения это не влияет. При этом утверждается, что остаточные соединения все же помогут сети подобрать оптимальные веса. Однако глубина собственной сети, обусловленная небольшим количеством, развернутых во времени наблюдений, практически исключает возможности взрыва или затухания градиента. По этой причине мы отказались от использования подобного усложнения конструкции сети.

Разбиение на тренировочную и валидационную было сделано с аналогичным временным порогом для всех изучаемых отраслей, как и в случае полносвязной нейронной сети, который соответствует январю 2015 года. Результаты теста нейронной сети на валидационной выборке для четырех индексов представлены в таблице 11.

Таблица 11 – Результаты применения обученной сверточной нейронной сети на тестовой выборке

| Индекс | Точность | | Полнота | | Среднее гармоническое для H0 | Среднее гармоническое для H1 |
|--------|------------------|------------------|-------------------|-------------------|------------------------------|------------------------------|
| | PrH ₀ | PrH ₁ | RecH ₀ | RecH ₁ | | |
| CA | 0,64 | 0,68 | 0,74 | 0,62 | 0,69 | 0,65 |
| CB | 0,21 | 0,66 | 0,72 | 0,48 | 0,33 | 0,95 |
| DF | 0,56 | 0,62 | 0,84 | 0,54 | 0,67 | 0,58 |
| DJ | 0,62 | 0,67 | 0,28 | 0,9 | 0,39 | 0,77 |

4.1.3

Моделирование состояния отраслей при помощи логистической регрессии

В качестве бенчмарка для нейросетевых моделей прогнозирования используется логистическая регрессия. Регрессия в качестве входных данных использует аналогичные предыдущим моделям факторы: две выделенные главных компоненты и индекс в уровнях, в качестве объясняющих переменных, и бинарную переменную состояния в качестве объясняемой переменной. Разбиение на обучающую и валидационную выборки для всех индексов соответствует предыдущим моделям. Для оценки модели использовался пакет «sklearn». В процессе обучения логистической регрессии осуществляется поиск по стеке гиперпараметра регуляризации из логнормального распределения на промежутке от -2 до 2 и вида функции регуляризации.

Результаты применения оцененных моделей для каждого отраслевого индекса на тестовой выборке приведены в таблице 12

Таблица 12 – Результаты применения обученной логистической регрессии к тестовой выборке

| Индекс | Точность | | Полнота | | Среднее гармоническое для H0 | Среднее гармоническое для H1 |
|--------|------------------|------------------|-------------------|-------------------|------------------------------------|------------------------------------|
| | PrH ₀ | PrH ₁ | RecH ₀ | RecH ₁ | | |
| CA | 0,71 | 0,43 | 0,57 | 0,59 | 0,63 | 0,50 |
| CB | 0,2 | 0,77 | 0,5 | 0,46 | 0,29 | 0,58 |
| DF | 0,42 | 0,91 | 0,83 | 0,6 | 0,56 | 0,72 |
| DJ | 0,59 | 0,61 | 0,52 | 0,66 | 0,55 | 0,63 |

Для трех отраслей (CB, DF, DJ) модель хуже предсказывает рецессию, что связано, как с несбалансированными по классам (рост, рецессия) обучающими и тестовыми выборками, так и с неоптимальным выбором порога интерпретации вероятности. Для отрасли CA при определении фаз роста модель верно определила лишь порядка 50% периодов; для отрасли CB были верно предсказаны только около 30% фаз рецессии. В остальном результаты более приемлемые. Для отрасли DF сеть определяет правильно 56% рецессий и 72% периодов роста. Для отрасли DJ соответственно 55% рецессий и 63% роста.

4.2 Верификация и валидация полученных результатов

В разделе 4.1 Обучение и тонкая настройка нейросетевой модели обращалось внимание на несбалансированность классов (распределения периодов рецессии и роста) для некоторых отраслей. При работе с несбалансированными выборками по классам стандартной процедурой является верификация порога отсекающей вероятности, в соответствии с которым модели определяют фазу цикла: рост или рецессия. В пакете «sclearn» и в двух моделях нейронных сетей по умолчанию порог, интерпретирующий результаты оцененных вероятностей равен 0.5. Выбор оптимального порога, как правило осуществляется с наложением некоторых правил на соотношения точности и полноты классификации по одному из классов. Поскольку нам предпочтительнее не совершать ошибку первого рода (при Н0 – рецессия) чем ошибку второго рода: допускать возможность ошибаться модели, признавая рецессию в больших случаях там, где возможен рост, а не признавать в больших случаях рост, где возможна рецессия, то мы будем искать оптимальный порог отсекающей вероятности на основе полноты и точности предсказания рецессии. Точность классификации для рецессии – это доля верно предсказанных периодов рецессии среди всех образцов тестовой выборки, отнесенных классификатором к рецессии. Полнота классификации для рецессии – это доля верно предсказанных периодов рецессии среди периодов рецессии, наблюдаемых в действительности.

Стандартной процедурой при поиске оптимального соотношения точности и полноты в задачах классификации с несбалансированными выборками является максимизация метрики «f-score», что есть среднее гармоническое между метриками полноты и точности. Однако в большинстве случаев на имеющейся выборке более простой алгоритм – нахождения пересечения между точностью и полнотой классификации при равномерном распределении порога от 0 до 1 дает лучший результат. Пример нахождения такого порога на обучающей выборке для отрасли Добычи полезных ископаемых приведен на рисунке 20.




Рисунок 20 – Иллюстрация нахождения оптимального порога отсечения на основании пересечения метрик полноты и точности.

Алгоритм поиска оптимального порога был применен к каждой отрасли и каждой прогнозной модели, поскольку каждая модель дает индивидуальное смещение оптимального порога. В разделе 4.1 часть результатов оценок приведены уже с учетом использования алгоритма. Прогностические характеристики таких моделей без учета поиска оптимального порога не приводятся, поскольку это не имеет практического смысла в силу того, что использование алгоритма значительно повышает прогностические характеристики.

К части верификации полученных результатов относится использование альтернативных условий в методе Брая-Бошана при определении фаз экономического цикла для выбранных отраслей. Метод является чувствительным к выбору следующих ограничений: минимальная длина фазы цикла, минимальная продолжительность цикла. Данные ограничения необходимы для того, чтоб в процессе автоматического определения фаз цикла, периоды сезонного спада или стагнации не воспринимались, как рецессия в отрасли, а также восстановительный подъем не воспринимался за фазу роста. Как было сказано в части 3.1 Описание структуры базы данных, в качестве стартовых значений параметров нами были использованы параметры из работы Дубовского и Кофанова: минимальная длина фазы – 5 месяцев ($K=5$); минимальная продолжительность цикла – 10 месяцев. При этом для каждой отрасли мы использовали диапазон K от трех до 6 месяцев

и соответственно К варьировали продолжительность всего цикла. Для всех отраслей, кроме Производство кокса и нефтепродуктов, алгоритм наилучшим образом интерпретируемые точки выделил с изначально наложенными ограничениями. Для Производства кокса и нефтепродуктов экономически-интерпретируемый результат позволило получить снижение минимального ограничения на фазу цикла до четырех месяцев.

4.3 Описание полученных результатов, их интерпретация

В данном разделе на основании описанных выше расчетов сравниваются прогностические характеристики конкурирующих моделей, также приведено описание полученных результатов краткосрочного прогнозирования с использованием наилучшей модели для четырех изучаемых отраслей на месяц вперед.

Метрики качества прогноза для сравнения прогностических характеристик конкурирующих моделей приведены в таблице 13.

Таблица 13 – Сравнение прогностических характеристик между моделями: полносвязная нейронная сеть (NN); сверточная нейронная сеть (CNN); логистическая регрессия (LR)

| Отрасль | F1-score для H0 | | | F1-score для H1 | | |
|---------|-----------------|------|------|-----------------|------|------|
| | NN | CNN | LR | NN | CNN | LR |
| CA | 0.57 | 0.69 | 0.63 | 0.44 | 0.65 | 0.5 |
| CB | 0.25 | 0.33 | 0.29 | 0.47 | 0.95 | 0.58 |
| DF | 0.69 | 0.67 | 0.56 | 0.84 | 0.58 | 0.72 |
| DJ | 0.39 | 0.39 | 0.55 | 0.53 | 0.77 | 0.63 |

Метрика F1-score для нулевой гипотезы (H0 – рецессия) означает среднюю долю верно определяемых периодов рецессии на тестовой выборке между долей рецессий среди всех периодов, отнесенных классификатором к рецессии, и долей рецессий среди всех периодов действительно существовавшей рецессии. Метрика f1-score для H1 – аналогичный показатель для периодов роста. Для отрасли добычи полезных ископаемых (CA) по данному критерию наилучшей моделью является сверточная нейронная сеть с показателем f1-score, равным 0.69. Периоды роста также качественнее предсказывает для данной отрасли сверточная сеть (f1-score для H1 равно 0.65). Незначительно в точности определения периодов рецессии уступает логистическая регрессия (f1-score=0.63), однако периоды роста модель верно определяет лишь с 50% вероятностью. Наихудшие показатели точности демонстрируют полносвязные нейронные сети. Для отрасли добычи полезных ископаемых, кроме топливно-энергетических никакая из моделей не может предсказать рецессию с точностью более 50%, при этом периоды роста в 95%

предсказываются верно сверточной нейронной сетью и значительно хуже прочими классификаторами. Невозможность использовать модель для определения периодов рецессии скорее всего связана с несбалансированной по классам выборкой на тренировочной и тестовой части. Однако высокий f1-score сверточной сети для роста и одновременно низкий для периодов рецессии говорит о том, что при помощи варьирования порога отнесения вероятности общий результат может быть улучшен. Однако для этого оказалось недостаточно использованного, в нашем случае, метода приравнивания метрик полноты и точности. Максимизация f-score также дает смещенный результат в сторону определения всех периодов роста. При этом остается еще ряд возможных оптимизаций, не испробованных в данном случае. Для отрасли производства кокса, нефтепродуктов и ядерных материалов в точности определения фаз рецессии и роста лидирует полносвязная нейронная сеть с показателями f-score 0.69 и 0.84 соответственно. Сверточная нейронная сеть на сопоставимом уровне улавливает периоды рецессии (f1-score=0.69), а периоды роста определяет правильно лишь в 58% случаев, что несколько хуже, чем логистическая регрессия (f1-score=0.72). Для отрасли металлургическое производство и производство готовых металлических изделий наилучший результат при определении периодов рецессии на тестовой выборке демонстрирует логистическая регрессия с f1-score=0.55. Нейросетевые модели ошибаются в более, чем 50-ти процентах случаев. Точность определения периодов роста у логистической регрессии равняется 0.61. При этом сверточная нейронная сеть правильно определяет периоды роста в 77% случаев. Таким образом, снова наблюдается ситуация неверно выбранного соотношения полноты и точности. Полносвязная нейронная сеть для данной отрасли демонстрирует низкие прогностические возможности: предсказывает верно периоды роста лишь в 53% случаев, а периоды рецессии предсказывает более точно, если интерпретировать прогноз наоборот.

Общей тенденцией для всех классификаторов является более точное определение периодов роста, что связано с несбалансированной в случае каждой отрасли выборкой по классам. Обучающие выборки содержали большее количество учебных образцов с периодами роста, в результате чего модели на тестовых выборках чаще верно определяли периоды роста (и даже там, где их быть не должно, о чем свидетельствуют высокие значения метрик полноты с одновременно низкими значениями точности). Именно по этой причине мы использовали алгоритм поиска оптимального соотношения метрик полноты и точности для класса, соответствующего рецессии. Однако найти «золотую середину» использованный алгоритм не помог, хотя и несколько улучшил результаты.

Возможно, для более качественного улучшения необходимо искать оптимальное соотношение между гармоническими средними полноты и точности для двух классов, для чего требуется определить оптимальную форму их функциональной зависимости.

По результатам приведенных метрик сложно отдать предпочтение определенной прогнозной модели. Каждая модель сумела продемонстрировать сравнительно лучшие метрики в определенной отрасли. Нейросетевые модели оказались лучшими в предсказании фазы в трех из четырех проанализированных отраслей, как в определении периодов роста, так и периодов рецессии. Логистическая регрессия оказалась предпочтительнее для металлургической отрасли. Это говорит о том, что в зависимости между макрофакторами, описывающими поведение отрасли, скорее отсутствуют нелинейные связи и линейная логистическая регрессия справляется с задачей прогнозирования в таком случае лучше.

Для прогнозирования текущей экономической ситуации в отраслях, с учетом доступной статистики на сентябрь 2019 года, мы будем использовать модели, продемонстрировавшие наилучшие прогностические качества. Для отраслей: добыча топливно-энергетических полезных ископаемых и добыча полезных ископаемых, кроме топливно-энергетических – это сверточная нейронная сеть, которая показала лучшие значения f1-score, как при определении периодов роста, так и периодов рецессии. При этом мы учитываем, что для отрасли СВ прогнозирование рецессии может быть крайне ненадежным. Для производства кокса, нефтепродуктов и ядерных материалов – это полносвязная нейронная сеть, которая также показала лучшие, среди прочих, метрики обоих классов. Для металлургического производства и производства готовых металлических изделий нет выявлено лучшей модели, поскольку логистическая регрессия предсказывает лучше рецессию, а сверточная нейронная сеть – рост. Однако в силу того, что совершать ошибку первого рода при нулевой гипотезе – «рецессия» менее предпочтительно, чем ошибку второго рода, то мы выбираем в качестве прогнозирования для данной отрасли логистическую регрессию.

Для прогноза на месяц вперед (на октябрь 2019 года) в отраслях СА и СВ сверточной нейронной сетью используется окно данных в два квартала: с апреля по сентябрь 2019 года, поскольку один обучающий образец сверточной сети включал 6 значений (два квартала) каждого ряда: индекса производства отрасли и двух главных компонент. Для выделения главных компонент из используемых наборов факторов применялась модель нейросетевого автокодировщика с параметрами, обученными на всей имеющейся исторической выборке. Для оценки вероятности рецессии в отраслях DF, DJ в

качестве входных данных использовались выделенные главные компоненты по тому же принципу и значения индексов производства за последний месяц.

Расчеты показывают, что в октябре 2019 г. российская экономика находится в фазе рецессии в трех из четырех отраслей: добыча рудных полезных ископаемых; производство кокса, нефтепродуктов и ядерных материалов; металлургическое производство, и производство готовых металлических изделий. Только отрасль Добычи топливно-энергетических полезных ископаемых, согласно расчетам, демонстрирует рост. Однако, несмотря на техническое удовлетворение критериям спада, его амплитуда еще очень мала во всех «кризисных» отраслях. Относительно экономики в целом скорее всего правильно было бы говорить о ее стагнации на фиксированном уровне, однако общепринятый метод датировки позволяет выделить только две фазы цикла – подъем и спад.

В данной главе описаны шаги по созданию прогнозных, конкурирующих моделей: полносвязной нейронной сети, сверточной нейронной сети, логистической регрессии. Тестирование моделей проводилось на унифицированных данных, в качестве метрики качества предсказания использовался f1-score (среднее гармоническое между точностью и полнотой классификации). Каждая модель сумела продемонстрировать сравнительно лучшие метрики в определенной отрасли. Сверточные нейронные сети оказались лучшими в предсказании фазы, как в определении периодов роста, так и периодов рецессии, в отраслях: «добыча топливно-энергетических полезных ископаемых»; «добыча полезных ископаемых, кроме топливно-энергетических». Полносвязная нейронная сеть на тестовой выборке сработала лучше остальных для отрасли «производство кокса, нефтепродуктов и ядерных материалов». Логистическая регрессия оказалась предпочтительнее для металлургической отрасли. Это говорит о том, что в зависимости между макрофакторами, описывающими металлургическую отрасль, скорее отсутствуют нелинейные связи и линейная логистическая регрессия справляется с задачей прогнозирования лучше. Общей тенденцией для всех классификаторов является более точное определение периодов роста, что связано с несбалансированной в случае каждой отрасли выборкой по классам. При помощи моделей, продемонстрировавших лучшие прогностические характеристики в отрасли, были построены краткосрочные прогнозы.

ЗАКЛЮЧЕНИЕ

Целью исследования является прогнозирование выпуска в основных секторах отечественной экономики в соответствии с общероссийской классификацией видов экономической деятельности. В своем подходе мы предлагаем прогнозировать состояние четырех отраслей. Индикаторами состояния отраслей являются индексы производства по структуре ОКВЭД, два из которых относятся к разделу «добыча полезных ископаемых»: добыча топливно-энергетических полезных ископаемых; добыча полезных ископаемых, кроме топливно-энергетических. И два к разделу «обрабатывающие производства»: производство кокса, нефтепродуктов и ядерных материалов; металлургическое производство и производство готовых металлических изделий.

Для того, чтоб иметь максимально возможную длину временных рядов применялся пересчет индексов из ОКВЭД2 в ОКВЭД2007. Логика построения прогноза для одного индикатора заключается в следующем: сперва для индекса определяются поворотные точки, разграничивающие периоды роста и рецессии, после чего на основе бинарного представления индекса (0-рецессия, 1- рост) и набора объясняющих факторов оценивается вероятность наступления рецессии в следующем периоде.

В силу того, что общепринятой классификации поворотных точек нет, мы обратились к зарубежному и отечественному опыту в поисках алгоритмической процедуры, которая бы минимизировала ручное вмешательство в процесс определения фаз цикла на исторических данных, а, следовательно, исключала субъективное представление исследователя. Результаты анализа свидетельствуют, что процедура Брая-Бошана (предложена Bry, Boschan, 1971; фактически алгоритмизированная процедура NBER США для определения поворотных точек в отдельном макроэкономическом ряде) является наиболее предпочтительной. Алгоритм устроен таким образом, что позволяет избежать смещения поворотной точки относительно ее истинного положения вправо в отличие от поиска локальных максимумов и минимумов на очищенном от сезонности сглаженном ряде. Это возможно благодаря тому, что индекс сперва сглаживается с помощью четырех различных фильтров, а затем полученные ряды датируются независимо (при помощи поиска локальных максимумов и минимумов), после чего на менее сглаженных рядах остаются только точки, которые находятся в окрестностях точек на более сглаженных рядах. При этом на каждом этапе отбор должен соответствовать требованиям: пик чередуется с дном, ограничением на минимальную длительность фазы, ограничением на дисперсию. В свое время Брай и Бошан на основе американского опыта определили, что для месячных данных лучше всего подходит ограничение на фазу $K > 5$

месяцев (в то время как для квартальных $K > 2$). Для разграничения фаз цикла в выбранных индексах промышленного производства мы применили алгоритм с параметрами из работы Дубовского, Кофанова, а также используем различные K для того, чтобы оценить стабильность полученных результатов.

Полученные в результате применения алгоритма поворотные точки на пересекающейся части выборки (с 2000 по 2015 год) для отраслей из раздела добычи полезных ископаемых оказываются близки к поворотным точкам индекса промышленного производства (в который входит вид деятельности «Добыча полезных ископаемых») Дубовского; для отраслей из раздела обрабатывающие производства близки к индексу обрабатывающих производств. На доступном оставшемся периоде полученные поворотные точки имеют экономически интерпретируемый характер.

Статистические данные, используемые нами при построении прогнозной модели для каждой отрасли, включают в себя в общей сложности 31 показатель и были разделены на три основные категории:

1. Опережающие показатели (индекс предпринимательской уверенности организаций по добыче полезных ископаемых; индекс предпринимательской уверенности по организациям обрабатывающих производств);
2. Показатели реального сектора (среднеотраслевые цены, стоимость труда, инвестиции в отрасль, стоимость электроэнергии, объем государственных субсидий, издержки транспортировки, доля квалифицированного труда в промышленности, ВВП основных стран импортеров);
3. Показатели финансового сектора (стоимость нефти, денежная масса, объем кредитов реальному сектору, валютный курс, средневзвешенные процентные ставки по кредитам нефинансовым организациям).

В силу того, что отечественная макростатистика располагает весьма ограниченным временным горизонтом, то при оценке моделей необходимо сокращать количество оцениваемых параметров, мы использовали снижение размерности данных вплоть до одной главной компоненты для каждой из трех категорий показателей. Для оптимального сжатия данных использовался нелинейный метод на основе нейросетевого автокодировщика, который по своей сути является аналогом ядерного метода главных компонент, но в отличие от него не требует априорного знания вида функции отображения.

Для построения прогнозов мы использовали три модели: полносвязную нейронную сеть, сверточную нейронную сеть и логистическую регрессию. По результатам

приведенных метрик сложно отдать предпочтение определенной прогнозной модели. Каждая модель сумела продемонстрировать сравнительно лучшие метрики в определенной отрасли. Неросетевые модели оказались лучшими в предсказании фазы в трех из четырех проанализированных отраслей, как в определении периодов роста, так и периодов рецессии. Логистическая регрессия оказалась предпочтительнее для металлургической отрасли. Это говорит о том, что в зависимости между макрофакторами, описывающими поведение отрасли, скорее отсутствуют нелинейные связи и линейная логистическая регрессия справляется с задачей прогнозирования в таком случае значительно лучше.

Общей тенденцией для всех классификаторов является более точное определение периодов роста, что связано с несбалансированной в случае каждой отрасли выборкой по классам. На тестовых выборках всех отраслей наблюдалось большее количество периодов роста, в результате чего каждая модель несколько точнее улавливает паттерны роста. Однако подобное объяснение не является исчерпывающим. Существует справедливое суждение о том, что каждый кризис является уникальным по своей структуре и предсказать его исходя из анализа исторических тенденций попросту невозможно, от чего структурные макроэкономические модели, наподобие моделей реального делового цикла, продемонстрировали свою полную несостоятельность. Аналогично, нейронные сети, «эксплуатирующие корреляции» в прошлом, могут воспринимать в качестве паттернов рецессии, только существовавшие ранее микро тенденции. Однако в защиту модельного статистического подхода, к которому относятся и эконометрические и нейросетевые модели, можно сказать следующее: в процессе моделирования не происходит попытки объяснить природу кризиса, а только лишь выявить мало очевидные кризисные тенденции, проявляющие себя в совместном изменении большого количества макроэкономических факторов.

Список литературы

- Энтов Р. М. Некоторые проблемы исследования деловых циклов // Финансовый кризис в России и в мире / Под ред. ЕТ Гайдара. М.: Проспект. – 2009..
- 1] Белянова Е. В., Николаенко С. А. Экономический цикл в России в 1998-2008 годах: зарождение внутренних механизмов циклического развития или импортирование мировых потрясений? // Экономический журнал Высшей школы экономики. – 2012. – Т. 16. – №. 1..
- 2] Белянова Е. В., Николаенко С. А. О датировке экономических циклов: мировой опыт и возможности его использования в российских условиях // Вопросы статистики. – 2013. – №. 8. – С. 30-41..
- 3] Burns A. F., Mitchell W. C. Measuring Business Cycles National Bureau of Economic Research // New York. – 1946..
- 4] Bry G., Boschan C. Cyclical Analysis of Time Series: Selected Procedures and Computer Programs. New York: NBER, Columbia University Press, 1971.
- 5] Дубовский Д. Л., Кофанов Д. А., Сосунов К. А. Датировка российского бизнес-цикла // Экономический журнал Высшей школы экономики. – 2015. – Т. 19. – №. 4.
- 6] Hornik K., Stinchcombe M., White H. Multilayer feedforward networks are universal approximators // Neural networks. – 1989. – Т. 2. – №. 5. – P. 359-366.
- 7] K. Z. G. L. M. Geert Bruinooge, Handbook on Cyclical Composite Indicators For business cycle analysis, Eurostat, 2017.
- 8] Stock J. H., Watson M. W. New indexes of coincident and leading economic indicators // NBER macroeconomics annual. – 1989. – Т. 4. – P. 351-394.
- 9] Koopmans, T. C., Measurement without theory, Review of Economic Studies 29, P. 161-72. - 1947.
- 10] Адериho Ю. А., Крюков А. Ф. Индикаторы входа и выхода из рецессии // Статистика и экономика. – 2010. – №. 6.
- 11] Пестова А. Предсказание поворотных точек бизнес-цикла: помогают ли переменные финансового сектора // Вопросы экономики. – 2013. – Т. 7. – С. 63-81.
- 12] Киселев А. В. Подходы к построению опережающих индикаторов экономической активности: российский опыт // Экономика и предпринимательство. – 2015. – №. 10-2. – С. 96-101.
- 13] Демидов О. Различные индексы прогнозирования экономической активности в России, 2008 // URL: <http://quantile.ru/05/05-OD.pdf> (дата обращения. – 2019).
- 14]

- Смирнов С. В. Российские циклические индикаторы и их полезность «в реальном времени»: опыт рецессии 2008-2009 гг //Экономический журнал Высшей школы экономики. – 2012. – Т. 16. – №. 4..
- СОИ НИУ ВШЭ - URL: <https://dcenter.hse.ru/mon/82746172.html>. [Дата обращения: 2019].
- R. Nilsson, «Composite Leading Indicators and Growth Cycles in Major OECD Non-Member Economies and recently new OECD Members Countries,» *OECD Statistics Working Papers*, 2006.
- Смирнов С. В., Кондрашов Н. В., Петроневич А. В. Поворотные точки российского экономического цикла, 1981–2015 гг //Экономический журнал Высшей школы экономики. – 2015. – Т. 19. – №. 4.
- Каукин А., Миллер Е. Новая методика Росстата и динамика отраслевых индексов производства в начале 2017 г //Экономическое развитие России. – 2017. – Т. 24. – №. 6.
- Koop G., Onorante L. Macroeconomic Nowcasting Using Google Probabilities☆ //Topics in Identification, Limited Dependent Variables, Partial Observability, Experimentation, and Flexible Modeling: Part A (Advances in Econometrics. – 2019. – Т. 40. – P. 17-40.
- Борочкин А. А. Использование статистики поисковых запросов в сети Интернет для краткосрочного прогнозирования макроэкономических переменных //Деньги и кредит. – 2013. – №. 8. – С. 27-32.
- Дробышевский С. М. и др. Эконометрический анализ динамических рядов основных макроэкономических показателей. – 2001.
- Гусев К. Ю., Бурковский В. Л. Априорный анализ статистических моделей динамики экономических показателей //Вестник Воронежского государственного технического университета. – 2011. – Т. 7. – №. 8.
- Oord A. et al. Wavenet: A generative model for raw audio //arXiv preprint arXiv:1609.03499. – 2016.
- Borovykh A., Bohte S., Oosterlee C. W. Conditional time series forecasting with convolutional neural networks //arXiv preprint arXiv:1703.04691. – 2017.
- He K. et al. Deep residual learning for image recognition //Proceedings of the IEEE conference on computer vision and pattern recognition. – 2016. – P. 770-778.