

Содержание

ВВЕДЕНИЕ	4
1 Анализ существующих подходов к прогнозированию в энергосистемах	12
1.1 Этапы краткосрочного прогнозирования	12
1.2 Проблемы прогнозов потребления на основе экспертной оценки	15
1.3 Степень влияние метеорологических факторов на потребление электрической энергии и мощности Самарской энергосистемы	19
1.4 Определение влияния метеорологических факторов на потребление электрической энергии и мощности Самарской энергосистемы	25
1.5 Методы прогнозирования, основанные на использовании искусственных нейронных сетей.....	33
1.6 Разомкнутые ИНС	42
1.7 Многослойные нейронные сети с перекрестными связями.....	45
1.8 Преимущества ИНС	46
Вывод по главе 1	53
2 Разработка статистическо-динамической модели потребления энергосистемы на базе искусственной нейронной сети	54
2.1 Выбор программного продукта для формирования модели прогнозирования ИНС.....	54
2.2 Формирование статистической базы почасового потребления мощности энергосистемы	58
2.3 Адаптация входных данных для обучения искусственной нейронной сети	60
2.4 Выбор алгоритма обучения ИНС для статистическо-динамической модели	60
2.5 Выбор архитектуры ИНС для модели прогнозирования энергосистемы	61
2.6 Сравнение результатов прогнозирования при различных моделях построения ИНС	65
Вывод по главе 2	73

3 Введение в модель прогнозирования сведений о метеофакторах, влияющих на характер электропотребления	74
3.1 Оценка качества прогнозирования модели ИНС на различных типах данных	74
3.2 Оценка эффективности введения в прогнозную модель данных влияющих на динамику потребления в энергосистеме.....	77
3.3 Оценка эффективности прогнозирования выбранной модели нейронной сети с возможностью учета метеофакторов.....	79
Вывод по главе 3	88
Заключение	89
Список использованных источников	91

ВВЕДЕНИЕ

Электроэнергетика является системообразующей отраслью Российской Федерации. От ее надежного функционирования зависит не только безопасность страны, но ее экономическое развитие. Функционирование электроэнергетики это сложный технологический и экономический процессы [2,3], в которых участвуют генерирующие, сетевые, сбытовые компании, потребители электрической энергии и мощности и системный оператор единолично осуществляющий диспетчерское управление в единой энергосистеме [2]. При этом эти два процесса сильно взаимно зависимые, так как для производства электроэнергии генерирующие компании обязаны поддерживать в постоянной готовности генерирующие мощности за счет своевременного проведения ремонтных компаний, а также иметь запасы топлива. В соответствии с Приказом Минэнерго России от 22.08.2013 №469, на тепловых электрических станциях (далее – ТЭС) должен поддерживаться запас топлива в количестве, необходимом для удовлетворения спроса на электроэнергию в энергосистеме страны в конкретный момент времени. Поэтому на данные мероприятия генерирующие компании должны постоянно вкладывать деньги. Такой же принцип работы и у сетевых организаций. Их функцией является передача электрической энергии конечному потребителю. В Стоимость услуг, данных организаций, входит в конечную стоимость каждого киловатт-часа потребленной электрической энергии. Таким образом, для обеспечения бесперебойной работы предприятий электроэнергетической отрасли оплата всех затрат должна проходить предварительно, а затраты связаны с работой этих предприятий, обеспечивающих гарантированную поставку электрической энергии в необходимом объеме и качестве в соответствии с ГОСТ 32144-2013.

Поэтому надежное функционирование технологического процесса зависит от экономического процесса, особенно это выражено в математической

модели функционирования оптового рынка электроэнергии и мощности на территории Российской Федерации [3]. Одним из ключевых рыночных механизмов ОРЭМ является процедура выбора состава включенного генерирующего оборудования (далее – ВСВГО). ВСВГО - это механизм определения того, какое генерирующее оборудование электростанции будет включено в ближайший день (плюс прогноз на два дня вперед). Он базируется на технических и ценовых данных от генерирующих компаний. Процедура ВСВГО является конкурентным отбором ценовых заявок генераторов и влияет на цену рынка на сутки вперед (далее - РСВ), так как определяет, кто из поставщиков будет предлагать свою электроэнергию на рынке в ближайшие сутки. Общая задача ВСВГО [30] – с максимальной надёжностью и минимальными затратами покрыть потребление электроэнергии. Сейчас в модели ВСВГО главным целевым параметром является минимизация стоимости включённого генерирующего оборудования с учётом прогнозного потребления электроэнергии и заданного объёма резерва, необходимого для обеспечения надёжности работы ЕЭС.

Исходной информации используемой для расчета ВСВГО являются данные о планируемых перетоках электрической энергии и мощности, краткосрочные прогнозы потребления электрической энергии и мощности энергосистем, которые складываются в прогноз потребления единой энергосистемы, объемы мощности включаемые по требованиям участников ОРЭМ, режимные генераторы находящиеся в работе для обеспечения максимального допустимого перетоков в сечениях в послеаварийных режимах работы энергосистем, объемы резервов на электрических станциях.

Следует отметить, что обеспечение надежности функционирования единой энергосистемы при оперативном планировании зависит от регулировочного диапазона включенного генерирующего оборудования по результатам ВСВГО и находящегося во включенном состоянии в операционных сутках для покрытия в потребности электрической энергии и

мощности, и обеспечение устойчивости функционирования энергосистем в нормальном и послеаварийном режимах работы. Так как состав генерирующего оборудования который должен находиться в работе в час X по результатам ВСВГО определяется на основании планируемого потребления электрической энергии и мощности в энергосистемах, то в конечном счете, от качества краткосрочного прогноза потребления электрической энергии и мощности зависит как конечная стоимость электрической энергии и мощности, надежное функционирование энергосистем, так и качество оперативного прогноза потребления электрической энергии и мощности.

Также на основании краткосрочного прогноза рассчитываются исходные и оптимальные электрические режимы энергосистем, оценивается их надежность, экономичность, качество электроэнергии [6].

Необходимо отметить, что оперативный прогноз потребления электрической энергии и мощности определяется исходя из текущей динамики потребления мощности на срез последней минуты каждого часа, но основным ориентиром для технолога который формирует прогноз потребления на планируемый период служит траектория потребления мощности заложенная в краткосрочном прогнозе потребления.

Таким образом, обеспечение высокой точности краткосрочного прогноза спроса на электрическую энергию и мощность в энергосистемах является приоритетной задачей.

Исходя из этого, необходимо обратить внимание на то, что оперативное прогнозирование потребления электрической энергии и мощности является составляющей краткосрочного прогнозирования, поэтому повышение точности оперативного прогнозирования невозможно осуществить без повышения точности прогноза выполненного на этапе ВСВГО, рынка на сутки вперед и при актуализации расчетной модели. Таким образом, в данной работе вопрос повышения качества оперативного прогноза потребления будет рассмотрен как

совокупность мероприятий повышения качества краткосрочного прогнозирования.

Краткосрочное прогнозирование потребления электрической энергии и мощности в энергосистемах, на сегодняшний день, включает в себя две составляющих: рыночные технологии и технические аспекты. Вопрос рассмотрения по отдельности каждой составляющей подобен рассмотрению целого пласта научных исследовательских работ, в которых подробно рассмотрены множество вопросов связанных с повышением точности краткосрочных прогнозов.

Прежде всего, хочется сказать, что, несмотря на большое количество приведенных работ по созданию специализированных программ и методов прогнозирования, данный вопрос не теряет актуальность, связано это не с низким качеством рассматриваемых вопросов, а с тем что прогнозные величины потребления утверждаются и формируются персоналом, т.е. проходят экспертную оценку, и поскольку процесс электропотребления носит сложный случайный характер, то всегда будет существовать ошибка прогнозирования.

Что касается рыночных технологий, то они регламентируются регламентом функционирования оптового рынка электроэнергии и мощности (далее – регламенты ОРЭМ) и определяют процедуру и временные рамки формирования краткосрочного прогноза потребления электрической энергии и мощности, а так же методику прогнозирования.

Рыночные механизмы ОРЭМ постоянно совершенствуются, а вопрос о переходе к новому регламенту ВСВГО и актуализации расчетной модели становится очевидным [30], в связи с этим встает вопрос повышении оперативности прогнозирования за счет снижения времени принятия аналитических решений и заключений специалистом осуществляющего краткосрочный прогноз потребления энергосистем.

Так как сам по себе процесс потребления электрической энергии, а если рассматривать в конкретный интервал времени, является случайным событием, то он зависит от множества факторов. Это могут быть факторы относящиеся к различным категориям: природные, климатические, технические, экономические, режимные и тд.

Необходимо отметить, что одним из важных технических факторов является состав потребителей энергосистем, что существенно влияет на зависимость потребления в энергосистемах электрической энергии (мощности) от разных категорий факторов. Если потребление населением в значительной степени зависит от погодных условий, естественного освещения и статуса дня (рабочий или выходной день), то потребление крупных промышленных предприятий зависит от технологического процесса производства и складывающейся экономической ситуации, и в меньшей степени от температуры наружного воздуха (далее – ТНВ), а при значительном доминировании в структуре потребления над населением в энергосистеме, влияние потребления электрической энергии и мощности в энергосистеме от ТНВ, будет не таким значительным по сравнению с энергосистемами, где основными потребителями являются мелкомоторная и коммунально-бытовая нагрузка. При этом изменения в экономике региона и страны в целом приводит к изменению характера потребления электрической энергии в энергосистемах за счет изменения режима работы промышленных потребителей, а это в свою очередь приводит к изменению степени влияния потребления от температурных и погодных условий. Соответственно структура потребителей на территории энергосистемы является неотъемлемым вопросом для изучения.

Существующий подход к прогнозированию потребления энергосистем основывается на статистических данных потребления электроэнергии в ретро-периоде. Существует значительная статистическая база потребления электрической энергии энергосистем, где хранится информация не только о фактическом потреблении соответствующего дня (рабочий или выходной

день), но и значения ТНВ которому соответствовало данное потребление. Это позволяет на основании имеющейся статистики подобрать такой характерный день, который приблизительно соответствует дню на который осуществляется краткосрочный прогноз, за счет этого с высокой точностью формируется краткосрочный прогноз потребления. Но у данного метода есть два недостатка, первое, он требует поиска соответствующего характерного дня, на что уходит достаточно много времени, и второе, на взгляд автора самым основным, при резко меняющихся режимах работы крупных потребителей, особенно если они не характерны для промышленного сектора, например экономический кризис, то статистическая база для таких режимов работы может отсутствовать, это приводит к увеличению времени на формирование прогноза за счет проведения огромного количества аналитических мероприятий, а так как временные рамки формирования краткосрочного прогноза жестко ограничены, то это в свою очередь приводит к увеличению погрешности прогноза потребления.

Поэтому возникает необходимость в создании статистическо-динамической модели энергосистемы, которая позволит формировать траекторию прогноза потребления на основании, статистики, текущей динамики потребления, фактической и прогнозных значений ТНВ.

Одним из регионов Российской Федерации, в котором сосредоточены крупные промышленные предприятия является Самарская область. Структура потребления представлена на рисунке 1.



Рисунок 1 - Структура потребления ЭС Самарской области

Из рисунка видно, что на долю промышленных потребителей приходится около 70% потребления, а на население всего лишь 11%, поэтому в данном регионе степень влияния потребления электрической энергии от различных факторов определяют промышленные потребители. Характер потребления по данному региону довольно стабильный, так как крупные промышленные потребители относятся к химической, нефтехимической, и автомобильной промышленности, однако кризисные явления 2015-2016 гг. изменили характер потребления предприятий, что привело к изменению степени влияния потребления Самарской энергосистемы от различных факторов.

Поэтому задача разработки динамической модели прогнозирования потребления мощности (электрической энергии) при оперативном планировании режима работы энергосистемы Самарской области является актуальной для разработки в научном сообществе.

Целью магистерской диссертации является повышение эффективности краткосрочного и оперативного планирования режима работы энергосистемы в результате разработки статистическо-динамической модели прогнозирования на примере Самарской энергосистемы.

Для достижения поставленной в магистерской работе цели необходимо решить следующие задачи:

- Проанализировать существующие методы прогнозирования;
- Выбрать программный продукт для построения прогнозной модели;
- Провести испытание выбранной модели на тестовой выборке данных;
- Рассчитать экономический эффект от использования полученной статистическо-динамической модели прогнозирования.

1 Анализ существующих подходов к прогнозированию в энергосистемах

1.1 Этапы краткосрочного прогнозирования

Так как современная модель функционирования оптового рынка электроэнергии (мощности) Российской Федерации (ОРЭМ) предъявляет повышенные требования к точности прогнозирования потребления электрической энергии (мощности), то самым сложным и требующим повышенной ответственности от специалистов осуществляющих прогноз электропотребления по территории субъектов Российской Федерации является краткосрочный прогноз потребления мощности [7]. Краткосрочное прогнозирование электропотребления является неотъемлемой частью при планировании режимов работы и составлении балансов электрической энергии и мощности по энергосистеме. Кроме того краткосрочные прогнозы является основой для формирования суточных диспетчерских графиков электропотребления. Благодаря краткосрочным прогнозам в быстрые сроки определяются необходимые объемы и размещение резервов мощности в ЕЭС.

Задачи краткосрочного планирования:

- обеспечение надежности функционирования и качества электроэнергии в энергосистемах;
- разработка оптимальных суточных графиков работы электростанций и электрических сетей энергосистем;
- обеспечение допустимых параметров электрических режимов.

Краткосрочное планирование регламентируется регламентами ОРЭМ и осуществляется в несколько этапов:

- ВСВГО;
- Рынок на сутки вперед (далее – РСВ);
- Актуализация расчетной модели (формирования прогнозного графика диспетчерских нагрузок);

- План балансирующего рынка (далее – ПБР).

План балансирующего рынка (ПБР) формируется по результатам конкурентного отбора ценовых заявок генерирующих компаний ОРЭМ. Для составления ПБР используется расчетная модель, что и при проведении торгов на РСВ, но содержащая актуализируемые в течение операционных суток параметры функционирования энергосистемы, а именно текущее потребление, типология электрической сети, регулировочный диапазон находящегося в работе генерирующего оборудования, резервы на электрических станциях и т.д. По результатам расчета ПБР Системный оператор определяет и доводит до участников рынка плановые графики работы электростанций и ценовые индексы балансирующего рынка (далее - БР).

Необходимо сказать о основных требованиях предъявляемых к диспетчерскому графику:

1. Сбалансированность потребления электрической энергии и генерации с учетом перетоков и потерь в электрических сетях;
2. Поддержание требуемых резервов мощности на электрических станциях для обеспечения компенсации потери наиболее крупной единицы генерирующего оборудования или сетевого элемента с учетом необходимости соблюдения ограничений перетоков мощности по контролируемым сечениям, в соответствии с СТО 59012820.27.010.007-2016 «Резервы активной мощности Единой энергетической системы России. Определение объемов резервов активной мощности при краткосрочном планировании», и в соответствии с СТО 59012820.27.100.003-2012 «Регулирование частоты и перетоков активной мощности в ЕЭС России. Нормы и требования»;
3. Поддержание требуемых уровней напряжения;
4. Поддержание требуемых параметров электроэнергетических режимов определяемых условиями надежной работы энергосистемы и отдельных объектов электроэнергетики.

Составление для составления краткосрочных прогнозов потребления использует детерминированные, статистические и расчетные данные:

- о конфигурации и величинах фактического потребления активной мощности на моменты окончания диспетчерских интервалов времени, зарегистрированных за аналогичные дни недели текущего и прошлого года;

- о значениях параметров, являющихся основными факторами, определившими профиль и величины фактического потребления зарегистрированными за аналогичные дни прошлого года.

К данным параметрам, как уже было сказано выше, относятся данные о фактической и прогнозируемой ТНВ, степень освещенности, долготу дня, события переносов выходных и праздничных дней; события сезонных переходов с зимнего на летнее время и обратно, наличие экстраординарных событий (катастрофы, массовые акции), прогнозы погодных условий, прогнозы состояния других факторов, влияющих на изменение потребления в соответствии с данными, полученными в результате обработки статистики потребления, о планируемом включении/отключении энергоемких производств;

Однако необходимо отметить, что прогнозные величины потребления утверждаются и закладывается персоналом, т.е. проходят экспертную оценку специалистом.

Поскольку процесс электропотребления носит сложный случайный характер, всегда будет существовать ошибка прогнозирования.

Так же хотелось бы отметить, что Системным оператором осуществлен переход на ежечасный расчет ПБР в 2016 году, что увеличило требования оперативности формирования оперативного прогноза потребления электроэнергии, в связи с ежечасным расчетом прогноза потребления, те необходимости постоянного анализа прогноза потребления, помимо выполнения других деловых процессов.

Хочется обратить внимание на сам вопрос прогнозирования потребления электрической энергии (мощности), что первоначально

повышения качества прогноза потребления электрической энергии или мощности. Что бы найти ответ на данный вопрос необходимо обратиться к существующим методикам краткосрочного потребления электрической энергии и мощности.

1.2 Проблемы прогнозов потребления на основе экспертной оценки

В начале, необходимо обозначить существующие методики прогнозирования, в основе которых используются методы статистического анализа, так как именно статистический метод, является базовым методом при формировании прогнозов потребления на основании экспертной оценки.

Самые распространённые методики прогнозирования, в основе которых используются методы статистического анализа:

1. Моделирование.
2. Экстраполяция.
3. Эвристический метод составления прогноза.
4. Регрессионные методы прогнозирования.

Прогнозирование эвристическим методом в общем случае характеризуется в виде опроса высококвалифицированного специалиста, который может составить общее видение развития конкретной ситуации и найти для данной ситуации решение. В данном случае предлагаемые пути решения основываются на знаниях и опыте, и в какой-то степени на профессиональной интуиции специалиста-эксперта. Из этого можно сделать вывод, что указанные факторы являются субъективными и зависят от личных качеств специалиста-эксперта, что является для эвристического прогнозирования существенным недостатком. При этом на практике данный подход очень часто применяется, но он не приемлем, так как очень многое зависит от конкретного специалиста-эксперта, а в случае не корректного прогноза последствия ошибочных решений, могут привести к некорректному

результату, так как на основе значений прогнозного потребления рассчитывается большое количество данных.

Однако следует отметить, что при длительной и качественной подготовке специалиста в данной области на основании большого объема анализируемой информации, составленные п специалистом-экспертом прогнозы, в большинстве случаев, по точности превосходят прогнозы, составленные на базе специализированных компьютерных программ или искусственного интеллекта. Однако такие результаты достигаются в случае если в энергосистемах режим работы не сопровождается непредвиденными событиями, т.е. происходит стабильное потребление электроэнергии за счет установившегося режима работы крупных потребителей или устоявшихся метеорологических условий.

В случаи сложных технических объектов или сложных технических и экономических процессов происходящих в энергосистеме, такой вид прогнозирования становится достаточно сложным и трудоемким. В связи с этим прогноз потребления может быть составлен не корректно. Пример некорректно составленного прогноза представлен на рисунке 2.

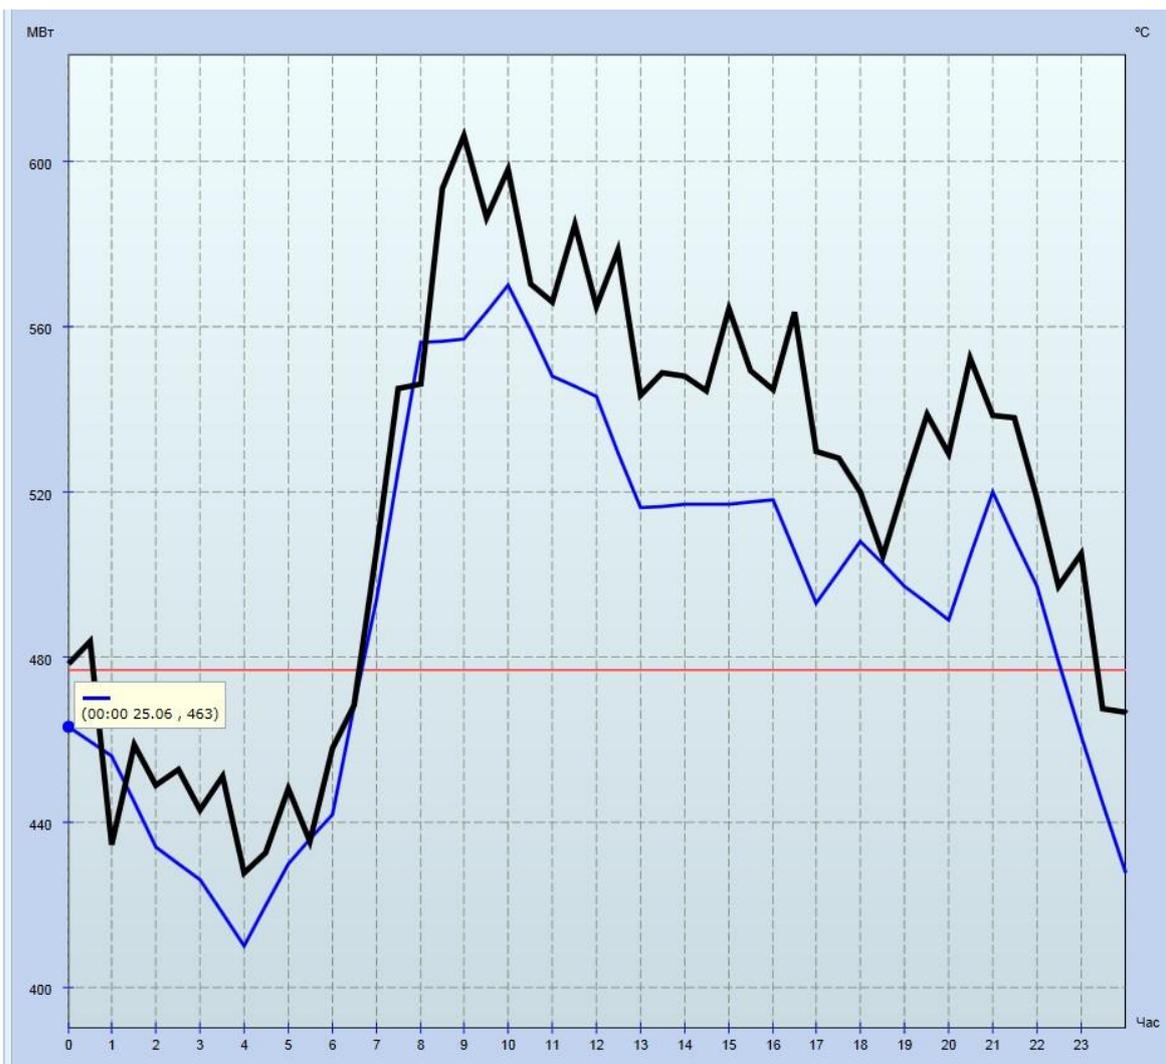


Рисунок 2 – Отклонение фактического потребления от прогнозного

На рисунке 2 отчетливо видно, что при планировании специалист учел не все факторы, которые повлияли на траекторию потребления мощности в энергосистеме. Это привело к значительному отклонению прогнозного потребления от фактического потребления.

Для снижения влияния субъективного мнения специалиста-эксперта, и формирования прогноза потребления на объективных расчетных данных, которые кроме того имели под собой и юридическую силу, были разработаны математические методы прогнозирования.

Главные достоинства математических методов прогнозирования:

- Объективность полученной информации;

- Возможность автоматизации процесса вычисления с помощью ЭВМ.

1.2 Статистические методы прогнозирования

Основным методом оперативного и краткосрочного прогнозирования потребления электрической энергии является статистический метод прогнозирования [7, 30]. К достоинствам статистического метода прогнозирования можно отнести тот, что его применение возможно без использования специализированного программного обеспечения (ПО). Основой точности составления прогнозов при использовании статистического метода, которая варьируется в пределах от 5% до 1%, является точный анализ характера текущего электропотребления (метод экспертной оценки) и статистических данных по электропотреблению за прошедшие аналогичные периоды. Так же, одним из достоинств статистического метода прогнозирования – минимальные финансовые затраты. Однако, применение данного метода прогнозирования требует большое количество времени на анализ характера текущего электропотребления и определения характерных периодов на основании статистических данных для формирования прогноза электропотребления.

Суть данного метода заключается в моделировании электропотребления энергосистемы, в виде случайного нестационарного процесса, который разделяется на несколько составляющих:

- регулярная составляющая – характерный тренд для характерного потребления складывающегося при одних и тех же событиях и который описывает устойчивые тенденции потребления на интервале времени.

Описание характерного тренда регулярной составляющей может быть представлено соотношением (1):

$$y_x = f \bar{a}_x + \eta_x ; \quad (1)$$

где $f(a, x)$ – регулярная составляющая, которая представляет собой в общем случае гладкую функцию от аргумента (времени), которую описывает вектор a , сохраняющий свое значение на всем протяжении составления прогноза. Эта составляющая соответствует линии тренда. Такая прямая лишена случайных составляющих и содержит в себе только те значения, которые описывают саму сущность процесса и учитывает только основные факторы, оказывающие влияние на ход развития процесса; x – нерегулярная составляющая описывающая случайную непрогнозируемую часть, а так же возможные отклонения фактических значений от устойчивых тенденций, выделенных из базового процесса; $\eta(x)$ – независимый случайный процесс, чье математическое ожидание равно нулю. Эту составляющую учитывают для увеличения точности прогноза.

«Выделенная в результате декомпозиции траекторию, выраженную в математическом виде, используют в дальнейшем в качестве прогнозирующей математической модели, т.е. модели, применяемой для расчёта прогнозных значений электропотребления мощности. Определение вида и параметров прогнозирующей модели выполняют путём аппроксимации известных значений электропотребления на ретро периоде в интервале времени и на интервале упреждения.» [27]

1.3 Степень влияние метеорологических факторов на потребление электрической энергии и мощности Самарской энергосистемы

«Существенное влияние на потребление электроэнергии оказывают метеорологические факторы - температура наружного воздуха, освещенность, влажность, скорость ветра. Они во многом определяют сезонные колебания, а также нерегулярные колебания графиков потребления. Наиболее значительное влияние на потребление оказывает температура и освещенность. Влияние температуры определяется расходом электроэнергии на определенные производственные процессы, отопление зданий, вентиляцию, охлаждение в холодильниках, кондиционерах. Для энергосистем (ЭС), где осветительная

нагрузка оставляет значительную часть, вариации естественной освещенности оказывают влияние на потребление, особенно на формирование утреннего и вечернего максимумов.» [25].

Проанализируем изменение потребления мощности в энергосистеме Самарской области от ТНВ с учетом изменения структуры потребителей вследствие кризисных явления в 2015-2016 годах.

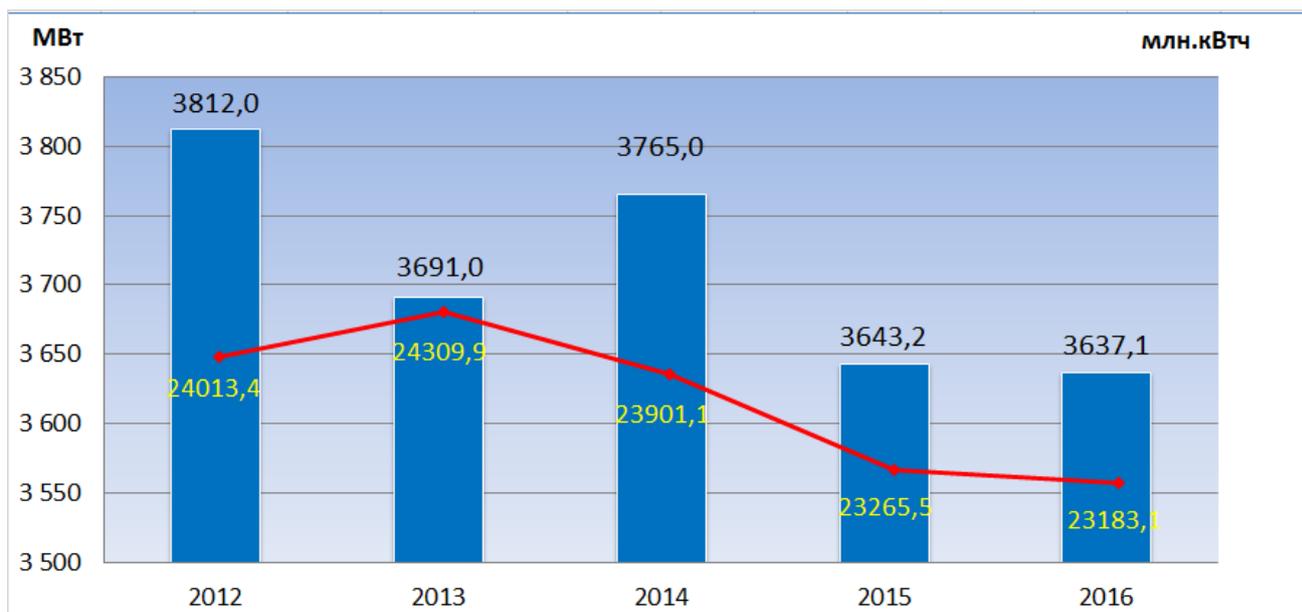


Рисунок 3 – Динамика потребления электрической энергии и мощности за последние 5 лет по ЭС Самарской области на основании данных из Схемы и программы развития

Из рисунка 3 видно, что в течение 3х последних лет с 2014 по 2016 год включительно наблюдается устойчивый спад потребления электрической энергии и мощности в следствии кризисных явлений в экономики региона и страны в целом. Вследствие чего, произошли структурные изменения состава потребителей электрической энергии и мощности по территории Самарской области.

Ни рисунках 4 и 5 представлены изменения среднесуточного потребления мощности и температуры в разрезе года при докризисном и в кризисном периоде.



Рисунок 4 - Среднесуточные значения потребления мощности и ТНВ для Самарской энергосистемы за 2015 год.

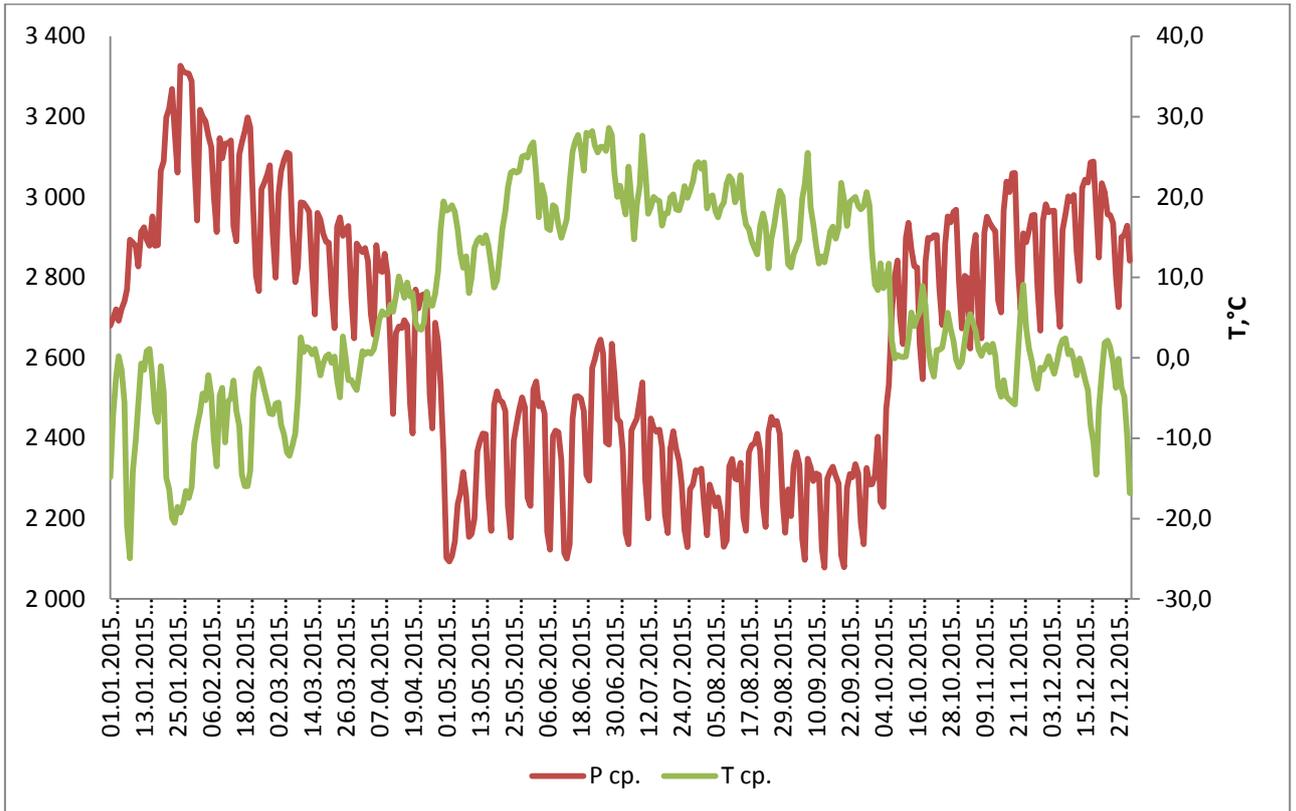


Рисунок 5 - Среднесуточные значения потребления мощности и ТНВ для Самарской энергосистемы за 2015 год.

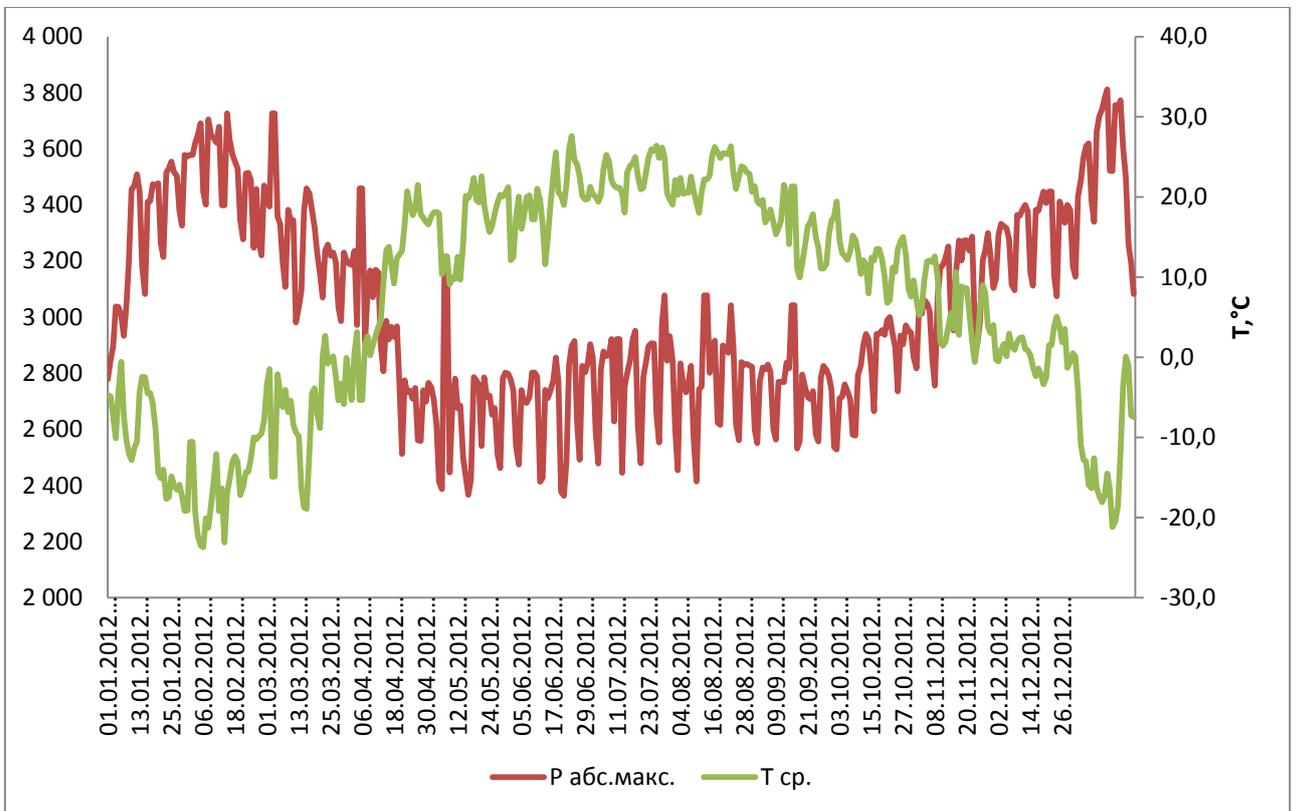


Рисунок 6 - Максимальные значения потребления мощности при среднесуточной ТНВ для Самарской энергосистемы за 2012 год.

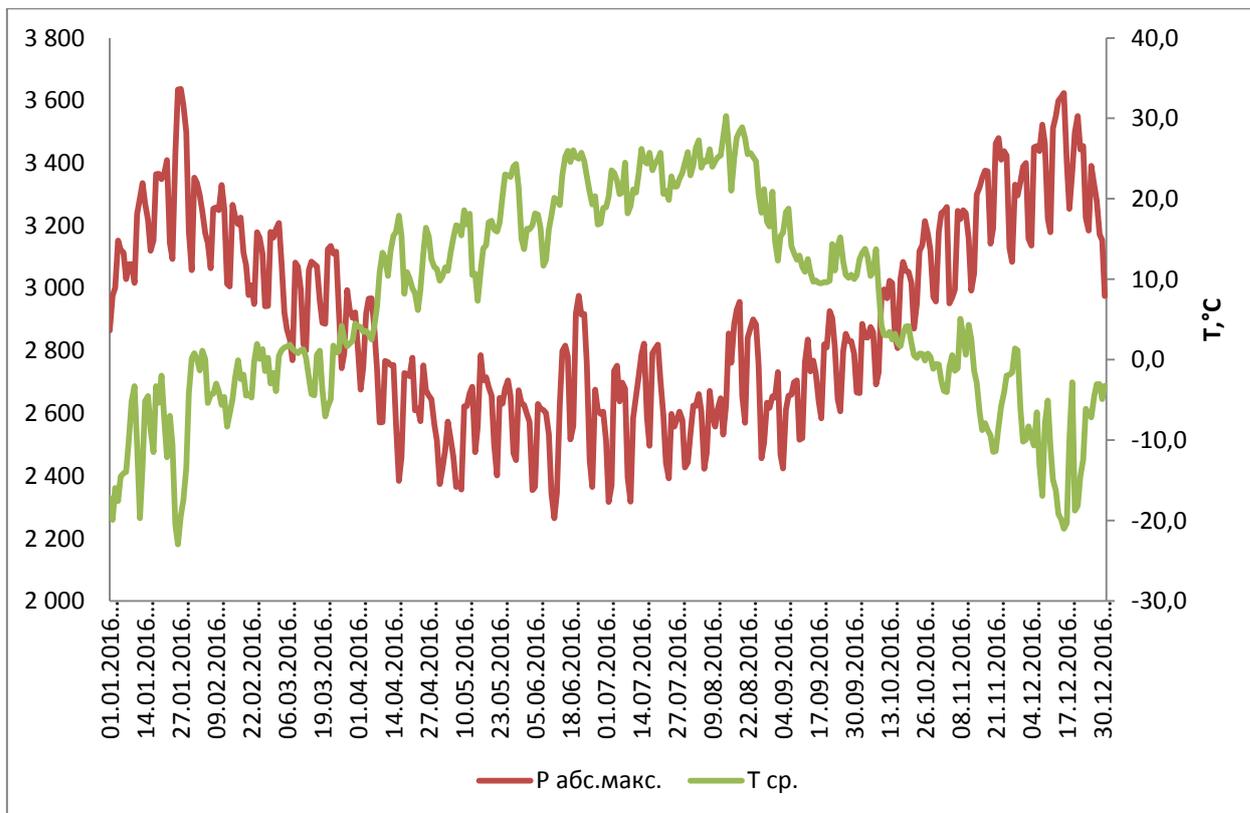


Рисунок 7 - Максимальные значения потребления мощности при среднесуточной ТНВ для Самарской энергосистемы за 2016 год.

Прежде всего, отметим, что на характер потребления промышленных потребителей существенное влияние оказывают сезонные и экономические факторы, которые определяют режим работы предприятий, ремонтных компаний и объемы выпускаемой продукции в зависимости от потребительского спроса. При этом влияние метеофакторов на характер электропотребления может быть неоднозначным и должен оцениваться для конкретных промышленных потребителей.

Кризисные явления в экономике Самарского региона и экономике страны существенно сказались на характере потребления крупных промышленных предприятий. Длительное снижение потребительского спроса заставило

предприятия снижать производственные издержки и объемы выпускаемой продукции, это привело к изменению режима работы предприятий.

Отметим следующие изменения режима работы крупных промышленных предприятий, которые существенно сказываются на характере потребления по ЭС в целом:

- переход с трехсменного режима работы на двух - односменный режим работы;

- переход с пятидневной рабочей недели на четырех дневную,

- снижение загрузки производственных мощностей оборудования крупных промышленных предприятий, доля потребления которых в энергосистеме составляет более 1%;

- сокращение персонала;

- останов производства;

- перепрофилирование производства и переход с одного вида экономической деятельности в другой.

Из рисунков 4 и 5 видно, что в 2015 году при изменении среднесуточной температуры в характере потребления мощности происходят резкие скачки потребления, данный характер потребления соответствует режиму потребления коммунально-бытовой нагрузки, при этом в докризисном периоде рисунок 4 данные провалы отсутствуют, т.е. происходит более плавное изменение потребления мощности при резких колебаниях температуры, что характерно для крупных промышленных предприятий с круглосуточным режимом работы (предприятия химическое и нефтехимической промышленности).

Таким образом, изменения электропотребления крупных промышленных предприятий, в следствии нехарактерного изменения режима работы, приводит к изменениям степени зависимости электропотребления энергосистемы от внешних факторов. Это происходит за счет изменения структуры потребления энергосистемы - снижение доли промышленной нагрузки, за счет изменения режима работы крупных предприятий, и увеличение коммунально-бытовой и

осветительной нагрузок и следовательно ведет к увеличению зависимости электропотребления от метеорологических факторов. Поэтому необходимо вести учет подобных изменений и фиксировать степень их влияния при составлении краткосрочного прогноза и оперативном планировании.

1.4 Определение влияния метеорологических факторов на потребление электрической энергии и мощности Самарской энергосистемы

Для определения степени влияния учета влияния метеорологических факторов, чаще всего проводится оценка влияния метеофакторов на потребление.

Оценка осуществляется с помощью корреляционного и регрессионного анализа. Для этого из фактических данных потребления и метеофакторов, выделяются регулярные компоненты в виде средних величин за определенные периоды (несколько дней).

$$\delta T(n) = T(n) - T_{cp}(n), \quad (2)$$

$$\delta P(n) = P(n) - P_{cp}(n), \quad (3)$$

где $P(n)$, $T(n)$ – фактические почасовые значения потребления и температуры; $P_{cp}(n)$, $T_{cp}(n)$ – регулярные компоненты (осредненные значения) потребления и температуры; $\delta P(n)$ – составляющая потребления, определяемая нерегулярными колебаниями метеофакторов; n – номер дня в году (1 – 365).

Регулярные компоненты определяются скользящим осреднением на определенном периоде от 3 до 30 суток (N).

$$P_{cp} = \frac{\sum_{i=1}^{i=N} P_i}{N} \quad (4)$$

$$T_{cp} = \frac{\sum_{i=1}^{i=N} T_i}{N} \quad (5)$$

Период усреднения N определяется подбором исходя из величины коэффициента корреляции.

Зависимость потребления от метеофакторов в целом нелинейна и имеет достаточно сложный характер. Для оценки их влияния применяются так называемые коэффициенты влияния. Они отражают линейную взаимосвязь отклонений нагрузки от регулярной составляющей $P_{cp}(n)$ (средних значений) и отклонений температуры (освещенности) от регулярной компоненты T_{cp} на 1°C .

Коэффициенты влияния температуры K_{TP} в абсолютных величинах и процентах определяются следующим образом:

$$K_{TP} = R_{TP} \cdot \frac{\sigma_p}{\sigma_T} \quad (6)$$

$$K_{TP} \% = \frac{K_{TP}}{P_{\text{средн}}} \cdot 100\% \quad (7)$$

где: R_{TP} - коэффициент парной корреляции отклонений температуры и потребления; σ_p , σ_T - среднеквадратичные отклонения потребления и температуры от регулярных компонент; $P_{\text{средн}}$ - среднее потребление за период.

Коэффициент корреляции R_{TP} , характеризующий степень линейной связи между двумя величинами, вычисляется по формуле [7]:

$$R_{xy} = \frac{K_{xy}}{\sigma_x \cdot \sigma_y} \quad (8)$$

$$K_{xy} = M\{ x t - M x \quad y t - M y \} \quad (9)$$

где K_{xy} - ковариационный момент; $x(t), y(t)$ - фактические значения; $M, M(x), M(y)$ - математические ожидания.

Исследуя динамику зависимости нагрузки от метеофакторов, следует учитывать некоторое запаздывание, связанное с инерционностью влияния температуры. Этот фактор отмечается давно и подтверждается многими исследованиями. Для качественной оценки этого явления используют корреляционную функцию. Расчет взаимной корреляционной функции показывает наличие явно выраженного запаздывания изменений электропотребления по отношению к изменениям температуры [25]. Взаимная корреляционная функция температуры и нагрузки достигает максимума:

$$K_{TP} t_1, t_2 = \text{Max при } t_2 = t_1 + \tau \quad (10)$$

«Значение τ колеблется в пределах 15 – 22 ч. При отсутствии запаздывания ($\tau = 0$) значение корреляционной функции тождественно коэффициенту корреляции.» [25]

Анализ корреляционных функций показывает, что они затухают достаточно медленно, имеется значимая связь на интервале до 100 ч. Максимального отрицательного значения функция достигает при задержке около 15-20 ч. Меньшие значения τ характерны для летних периодов, когда в жаркую погоду включаются приборы кондиционирования.

«Наличие факта запаздывания позволяет сделать важный вывод о том, что модель учета метеофакторов необходимо строить с учетом динамических свойств процессов.» [25]

Взаимная корреляционная функция достаточно устойчива и сохраняет основные параметры в течение нескольких лет. Колебания нагрузки значимо зависят от температуры нескольких прошедших суток. Вместе с тем достаточно использование трех суток - текущего, вчерашнего и позавчерашнего дня. Для более точного учета температуры может использоваться так называемая "эффективная" температура, дающая возможность учесть запаздывание

влияния температуры. Зависимость нагрузки от температуры рассчитывается с учетом эквивалентной переменной $T(n)$:

$$T_{\text{ЭКВ}} n = \alpha_1 T n + \alpha_2 T n - 1 + \alpha_3 T(n - 2), \quad (11)$$

где $\alpha_1, \alpha_2, \alpha_3$ – весовые коэффициенты; $T n - 1, T(n - 2)$ – соответственно температуры в текущий день, вчерашний и т.д. дни, часы и т.д.

Так как по Энергосистеме Самарской области существенно изменился характер влияния температуры на потребление в летний период за счет увеличения доли коммунально-бытовой нагрузки в структуре энергосистеме. Характер сезонных колебаний потребления приобрел свои особенности. В летний период наблюдаются также локальные максимумы в некоторых энергорайонах. Повышение летней нагрузки связано с дополнительной нагрузкой от приборов кондиционирования и поливным земледелием.

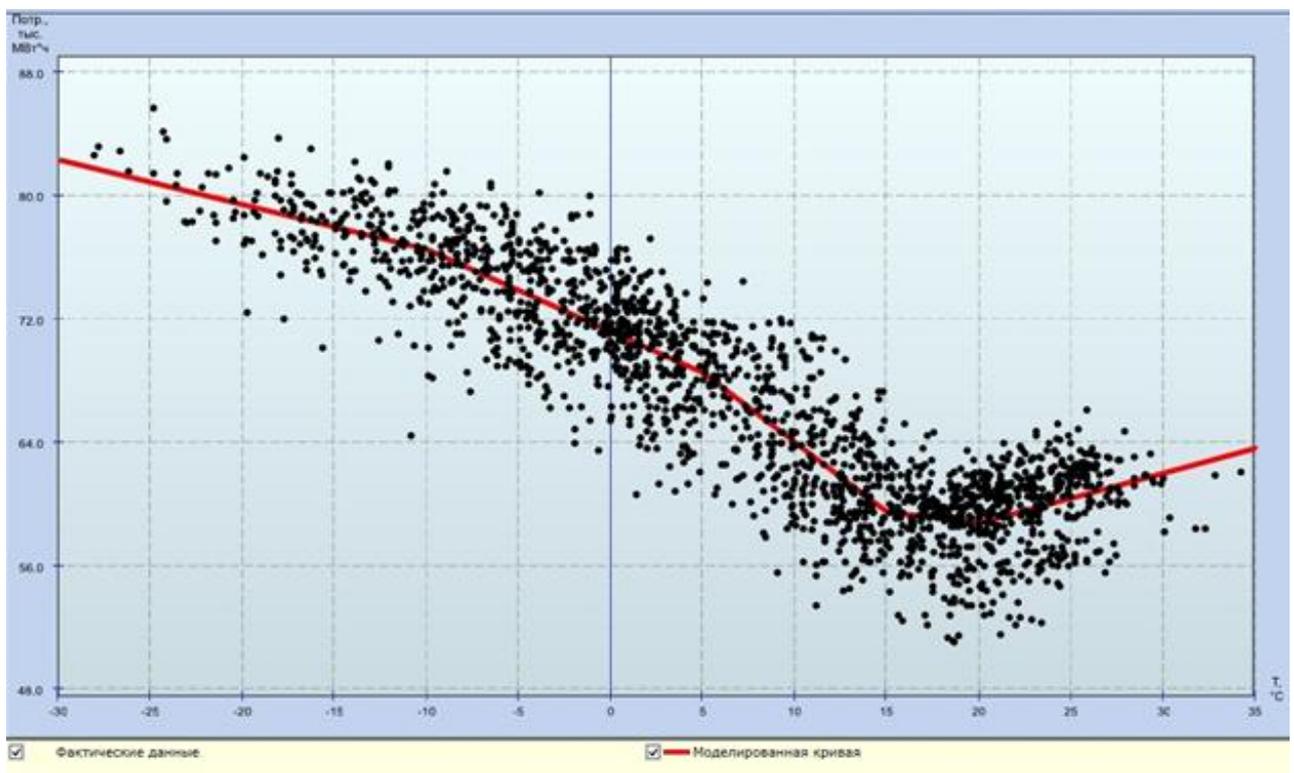


Рисунок 8 – Фактический максимум потребления по территории Самарской области в зависимости от ТНВ

На совмещенных графиках температуры и потребления рисунок 3 и 4 четко прослеживаются сезонные изменения температуры в разрезе года и нерегулярные колебания. Оценка влияния метеофакторов на потребление осуществляется с помощью корреляционного и регрессионного анализа. Для этого из фактических данных потребления и метеофакторов, выделяются регулярные компоненты в виде средних величин за определенные периоды (несколько дней).

Зависимость потребления от температуры представлена на рисунок 8. В целом отчетливо наблюдается снижение потребления при повышении температуры в диапазоне от -30 до +17 градусов и повышение потребление при повышении температуры от +17 и выше, что связано с кондиционированием воздуха в жаркую погоду.

В целом можно выделить несколько диапазонов влияния температуры, в которые степень влияния сохраняется достаточно стабильной и может быть моделирована линейным коэффициентом влияния [7].

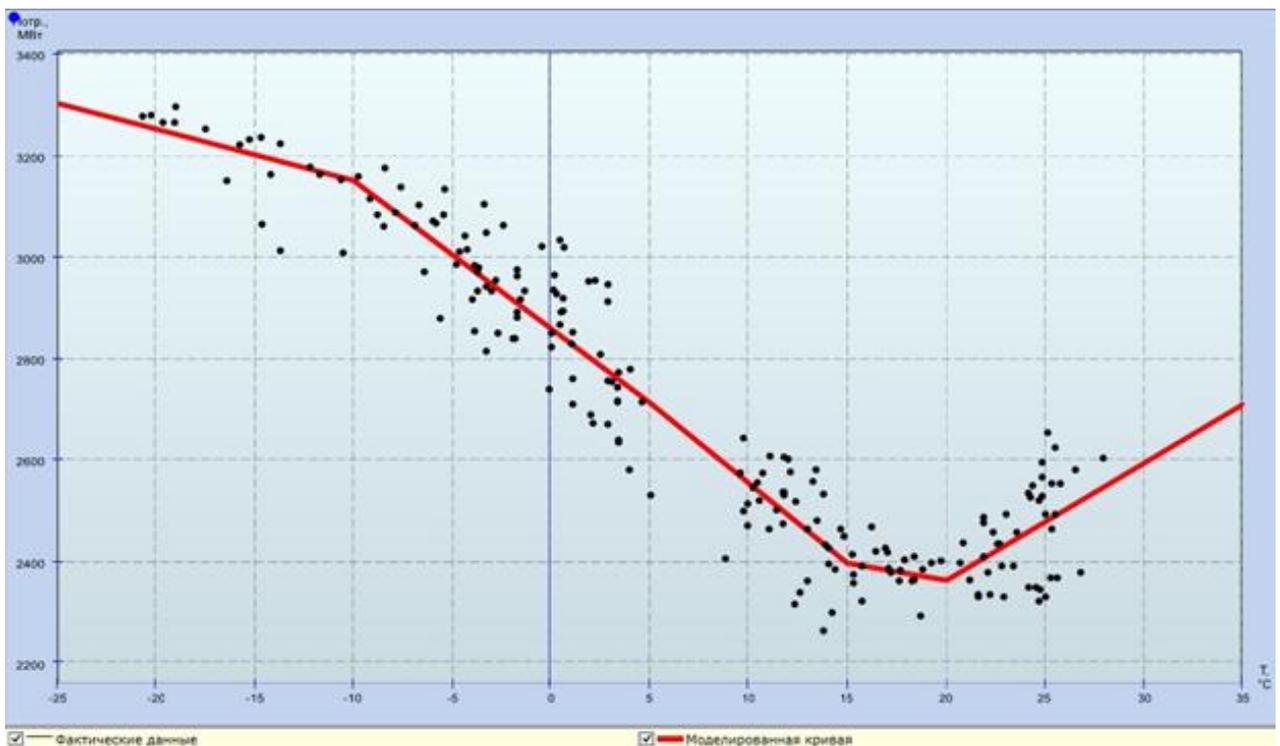


Рисунок 9 – коэффициенты влияния температуры в зависимости от величины температуры

На рисунке 9 представлены коэффициенты влияния температуры в зависимости от величины температуры. Температура разбивается на несколько диапазонов, в которые коэффициент влияния моделируется линейной функцией. Таких диапазонов может быть несколько, и они могут существенно отличаться для различных энергосистем. Задание диапазонов может производиться вручную технологом или рассчитываться автоматически.

Для этого реализуется специальный оптимизационный алгоритм, включающий задание в качестве входных ограничивающих параметров – минимальное и максимальное количество диапазонов, минимальную длину диапазона.

Результаты выборки температурных коэффициентов с 2007 года по 2016 год сведем в таблицу 1

Таблица 1 – Коэффициенты влияния температуры на потребление, %/°C 2007 - 2016, по электроэнергии, без учета запаздывания, по отклонениям от предыдущего дня

Года	Температурный диапазон				
	$-\infty \dots -10$	$-10 \dots 5$	$5 \dots 15$	$15 \dots 20$	$20 \dots \infty$
Итог	-0.25	-0.33	-0.36	0.24	0.5
2007	-0.17	-0.31	-0.51	0.07	0.48
2008	-0.41	-0.32	-0.49	0.16	0.46
2009	-0.91	-0.41	-0.43	-0.07	0.74
2010	-0.33	-0.24	-0.29	-0.04	0.32
2011	-0.22	-0.28	-0.35	0.02	0.56
2012	-0.17	-0.37	-0.39	0.14	0.53
2013	-0.27	-0.26	-0.46	0.24	0.5
2014	-0.44	-0.31	-0.43	0.46	0.33
2015	-0.41	-0.45	-0.62	0.31	0.56
2016	-0.72	-0.32	-0.49	0.16	0.62

Из таблицы видно, что выше утверждение о ежегодном изменении характера потребления в энергосистеме Самарской области за счет изменения структуры потребления и соответственно степени влияния потребления от ТНВ верны.

На рисунке 10 представлена сезонная кривая облачности для энергосистемы Самарской области, определения степени влияния облачности аналогично определению методики определения температурных коэффициентов.



Рисунок 10- Сезонная кривая облачности на основании метеостатистики по территории Самарской области

Таким образом, можно сделать вывод, что характер потребления энергосистемы определяется структурой потребления потребителей и в зависимости от соотношения промышленных потребителей и коммунально-бытовой нагрузки определяется степень влияния потребления в энергосистеме от различных факторов.

Наиболее существенное влияние на характер электропотребления коммунально-бытовой нагрузки и административных зданий и сооружений оказывают метеорологические факторы к которым относятся: ТНВ, естественная освещенность, влажность, скорость и направление приземистого ветра, характера и количества осадков. Влияние этих факторов во многом определяет сезонные колебания и суточную неравномерность графиков потребления электроэнергии и формирование утреннего и вечернего максимумов. Другими словами эти факторы определяют траекторию изменения часового потребления мощности в энергосистеме в течении суток.

На характер потребления промышленных потребителей существенное влияние оказывают сезонные и экономические факторы, которые определяют режим работы предприятий, ремонтных компаний и объемы выпускаемой продукции в зависимости от потребительского спроса. При этом влияние метеофакторов на характер электропотребления может быть неоднозначным и должен оцениваться для конкретных промышленных потребителей.

Так же хотелось бы отметить, что кризисные явления в экономике страны и в регионе существенно сказываются на характере потребления крупных промышленных предприятий. Длительное снижение потребительского спроса заставляет предприятия снижать производственные издержки и объемы выпускаемой продукции, это приводит к изменению режима работы предприятий. Все это приводит к изменению потребления промышленных предприятий, а так же к характеру изменения электропотребления от внешних факторов, что делает статистические данные электропотребления по энергосистеме трудно применимыми, а сам характер потребления суточного потребления по энергосистеме менее прогнозируемым, что существенно усложняет и ухудшает краткосрочный и оперативный прогноз.

В связи с этим встает вопрос о разработки новой методики краткосрочного и оперативного прогнозирования электропотребления, которая позволяла бы с минимальными временными и финансовыми затратами

учитывать и анализировать структуру потребителей энергосистемы, степень влияния отдельных факторов и длительность их воздействия на характер и уровень электропотребления исходя из текущей динамики электропотребления, прогноза погоды с такими параметрами как, ТНВ, естественная освещенность, скорость и направление приземистого ветра, количество осадков, динамики изменения ТНВ в течение нескольких сутках.

1.5 Методы прогнозирования, основанные на использовании искусственных нейронных сетей

Сегодня наблюдается большой интерес к применению методов, которые основаны на нелинейных моделях.

Основным элементом на котором основывается работа искусственного интеллекта является искусственный нейрон. Для понимания работы искусственного нейрона необходимо определиться с принципом работы нейрона человеческого мозга. На первом этапе определим понятия пластичности. Пластичность – способность головного мозга, позволяющая выстраивать нервную систему в соответствии с окружающими условиями. Такая способность является важной при обработке информации. В ИНС работа нейронов основана на аналогичном алгоритме. Искусственная нейронная сеть представляет собой такой аппарат, который позволяет моделировать различные процессы связанные с обработкой информации. Такие сети могут быть реализованы либо на уровне электронных компонентов, либо на базе моделей, которые создаются в программных продуктах.

Для оценки эффективности применения методов искусственного интеллекта (ИИ) по сравнению со статистическими и экспертными методами прогнозирования необходимо провести сравнительный анализ основных отличий данных методов.

Метод основанный на ИИ или искусственная нейронная сеть имеет способность добиваться высоких результатов при прогнозировании. Получение

высоких результатов связано в первую очередь не с большим количеством нейронов, входящих в ИНС, а с большим количеством связей между этими нейронами. Дадим определение искусственной нейронной сети.

Искусственная нейронная сеть (ИНС) — это параллельный распределительный процессор, который состоит из простейших частиц или моделей нейронов необходимых для обработки информации. Такой параллельный распределительный процессор может накапливать знания, которые он получает в процессе обучения. Так же он имеет возможность применять полученные знания для решения различного рода задач. Принципы решаемых задач должны быть похожи полученные в ходе обучения данные. Исходя из определения искусственной нейронной сети необходимо выделить следующие некоторые ее свойства. Следует учитывать так же, что эти свойства справедливы и для нейронов человеческого мозга.

Свойства ИНС:

- Обучение. Обучение – это процесс получения знаний и информации из внешней среды и дальнейшая обработке полученных знаний и информации нейронами;

- Накопление информации и знаний. Накопление происходит за счет создания связей между нейронами. Данные связи получили название - синаптические веса.

В настоящее время области применения ИНС огромны. Для некоторых областей применение алгоритмических или статистических методов неэффективно или невозможно. К таким областям, относятся:

1. Распознавание различного рода информации (текстовой, графической, голосовой)
2. Контекстная реклама в сети интернет;
3. Метеопрогнозирование;
4. Биржевое прогнозирование.

Применительно к теме диссертационного исследования можно выделить, что применение моделей и методов ИНС для нужд краткосрочного прогнозирования потребления электрической энергии и мощности является перспективным. Огромное количество производителей программного обеспечения (ПО) представляют на рынке свои программные продукты работы которых, при составлении прогнозов, основывается на применение методов ИНС.

Уже долгое время существуют два принципиальных подхода направленных на обработку информации. Первым можно выделить последовательную обработку символов, а вторым параллельное распознавание образов. Отличием символов от образов заключается в размерности, но принципы обработки не меняются. Размеры образов могут на несколько порядков превышать размеры символов. Может показаться, что различия в размерностях могут привести, к увеличению времени обработки информации. Однако, мы можем доказать, что с возрастанием размерности информационного блока приводит к возрастанию и сложности его обработки того блока компьютером. Причем возрастание сложности обработки блоков компьютером носит нелинейный характер.

Простота обработки символов связана с возможностью создания такого процессора, который мог предсказуемым образом обрабатывать все входящие символы - данные или сигналы, а так же мог производить с ними различные операции. Для образов, создание такого процессора не возможно. Так как количество различных образов огромно и для их запоминания потребовался бы процессор с очень большой мощностью. Поэтому мы можем сделать вывод, что вместо увеличения мощности процессора, необходимо изменять способы обработки информации, т.е. процессор для обработки образов, должен обладать минимальным набором образов-примеров, но такой набор образов-примеров позволил бы самостоятельно определить стратегию поведения с принятием решения. Следует понимать, что принимаемые в таком случае решения должны

быть аналогичны полученным ходе обучения. Кроме того, они должны адекватны с поставленной задачей. Можно сделать вывод, что различие между последовательными и параллельными вычислениями состоит в принципиальном различии в подходах обработки входящей информации.

Реализованные на принципах последовательной обработки символов ограниченной длины компьютеры, работают на архитектуре фон Неймана. Этот подход является традиционным для машин такого типа. Работа нейрокомпьютеров основана на принципах параллельного вычисления и распознавания образов. Данный принцип делает работу компьютеров схожей с работой человеческого мозга. Что бы подчеркнуть отличия в подходе к обработке информации приведем пример. Для получения численного значения какого-либо выражения компьютеру понадобятся доли секунд, в зависимости от сложности выражения. Но человеку, в любом случае понадобится более длительное время для получения ответа. В то время как узнать лицо человека, для другого человека не является трудной задачей и он делает это моментально. Однако для компьютера данная задача окажется трудновыполнимой.

Поэтому основной задачей нейрокомпьютеров является обработка образов. Для таких компьютеров не характерно разделение на активный процессор и пассивную память. Все вычисления, а так же процесс обучения распределяются по искусственным нейронам сети. По этому принципу они сходи с человеческим мозгом. Такое разделение позволяет нейрокомпьютеру иметь высокую производительность. Производительность нейрокомпьютеров может превышать на много порядков производительность традиционных машин.

По сравнению с параллельными вычислениями можно выделить ряд преимуществ нейросетевой архитектуры компьютера:

- 1) Возможность параллельной обработки информации;
- 2) Единство принципов обучения для всех нейронов ИНС;

3) Надежность. Выход их строя одного или группы нейронов не влияет на функционирование компьютера;

4) Способность к решению нестандартных задач.

Отличия в развитие человека и компьютеров можно описать так: человек, человек в начале учится распознавать образы и только после этого учится логически мыслить. Развитие компьютерной техники происходит по кардинально иному пути. В компьютеры изначально был заложен принцип последовательности вычислений, а затем, с помощью применения специальных программ, которые позволяют выполнять эмуляцию нейросетевой архитектуры на процессорах основанных на последовательном вычислений, они могут распознавать образы. Существуют аппаратные методы построения параллельной архитектуры вычисления. Однако данные методы сложны в своей реализации по сравнению с созданием специализированного ПО.

Появление класса новой вычислительной техники - нейрокомпьютеров обусловлено с одной стороны стремительным развитием элементной базы, а с стороны связано с необходимостью решения конкретных математических задач.

Изначально, развитие нейрокомпьютеров связано с развитием пороговой логики. Свое название, нейрокомпьютеры получили из-за условного названия порогового элемента, который имеет с фиксированные или настраиваемые веса и реализует простейшую передаточную функцию – принцип нейронов головного мозга.

Значительный прорыв для нейрокомпьютеров произошел в 80-х годах двадцатого века. Этот прорыв связан с появлением возможности эмуляции нескольких элементов (нейронов) и множества связей между нейронами. Эта эмуляция смогла быть выполнена на одном или нескольких кристаллах процессора, что было до того момента нереализуемым. Такую реализацию позволили осуществить методы электронной и оптической схем построения компьютеров.

Основной принцип, на котором основаны нейрокомпьютеры - принцип аналого-цифрового построения. Такое построение позволяет выполнять быстрые вычисления в пороговом элементе в аналоговой части, а реализация алгоритмов настройки весов происходит на цифровых системах.

Основой логики любой вычислительной системы - группа операций, которая составляет основную часть. Эта группа реализуется на основных элементах операционного устройства. Рассматривая нейрокомпьютеры, требуется наложение системы программирования на логический базис вычислительной системы. Чаще всего базисом вычислительной системы является базис вида $\{\sum \bar{a}x, sign\}$. Данный базис максимально согласован с базисом решаемых задач. Используя данный базис и выполняя решение будет происходить в системе с аналогичным базисом. Такое допущение позволяет избегать искусственных сдвигов в решении задач. Все это в результате позволяет выполнять решение задач с максимальной производительностью.

Другой особенностью нейронных компьютеров – структура. Структура нейронных компьютеров может быть рассчитана аналитическим путем, а структура традиционных компьютеров получена эмпирическим путем. Она получается из субъективных представлений о решаемой задаче.

Задачи, которые могут быть решены в подобных системах можно классифицировать следующим образом:

- 1) Формализуемые задачи;
- 2) Задачи трудно формализуемые;
- 3) не формализуемые задачи.

Формализуемыми задачами называются такие задачи, алгоритм решения для которых ясно очевиден.

Ко второй группе, трудно формализуемых задач, можно отнести задачи имеющие множество путей решения или эти решения невозможно оценить с точки зрения их качества или же достижимости этого решения в принципе.

В особый класс выделяются задачи, которые получили название неформализуемые. Данные задачи названы так потому что в алгоритме их решения присутствуют функции или данные, которые заданы неявно. Ниже выполним классификацию такого рода задач:

- 1) Задачи кластеризации;
- 2) Задачи связанные с распознаванием образов;
- 3) задачи требующие самообучения;
- 4) задачи связанные с получением прогнозов.

Сходство ИНС головного мозга несомненно. Эти процессоры имеют аналогичную структуру которая состоит из большого числа мельчайших процессоров. Эти процессы функционируют параллельно и имеют множественные связей. При схожести структуры, они демонстрируют и схожесть способностей. Способностями являются – обучение, которое происходит на основе опыта при решении примеров. Во-вторых обобщение, т.е. отделение значимых данных от посторонних во всем информационном потоке. Все эти способности проявляются не смотря на значительные допущения при создании ИНС.

ИНС обладают способностью к перестроению, если происходит изменение внешних условий. Процесс перестроения выглядит следующим образом. После изменения входного сигнала, ИНС сама настраивается и обучается для того чтобы новый выходной сигнал начал обеспечивать правильную реакцию на изменения окружения. Правильно обученная ИНС является устойчивой к малым изменениям внешней среды. Это свойство позволяет ИНС продолжать определять нужный «образ» и продолжать отделять шумы в потоке входных данных.

Для построения модели нейронной сети, которая была бы способна адекватно и с требуемой точностью решать поставленные задачи, необходимо выполнение следующих процедур:

1. Описание объекта, который выступает как входной сигнал для ИНС. Входными сигналами могут являться исходные значения переменных или начальные значения определяемых величин. Для задачи прогнозирования – входным сигналом будут являться данные о величине электропотребления за аналогичный период в прошлом.

2. Определение объекта, т.е. объекта выступающего как входящий сигнал. Таким объектом могут быть искомые значения переменных. Для случая краткосрочного прогнозирования электропотребления, объектом является почасовой график электропотребления потребления на сутки вперед.

3. Определение целевого входного сигнала. Для случая прогнозирования электропотребления целевой входной сигнал - величина электропотребления, к которой ИНС должна приблизить выходные данные, т.е. прогнозные значения.

4. Определение архитектуры ИНС. В архитектуру ИНС включены: количество слоев сети, способы связи слоев и весовые коэффициенты.

5. Определение функции. Должна быть определена функция с помощью которой ИНС могла бы «исправлять» возможные отклонения выходного сигнала от действительного.

6. Определение критериев оценки качества работы ИНС.

7. Определение значений синаптических весов для ИНС. Для определения весов используются следующие способы, такие как аналитический, т.е. при непосредственной постановке задач, способ основанный на использовании аналитических методов, а так же способ основанный на настройке коэффициентов ИНС.

Решение задачи с использованием ИНС предполагает, что сеть будет работать в определенном режиме и выполнять обработку конкретных данных.

Алгоритм решения задачи:

1. Разработка структуры ИНС отвечающей поставленной задаче;

2. Определение весовых коэффициентов ИНС или же выбор весов из памяти, если их вычисление выполнено до этого. Последнее свойство в дальнейшем будет использовано работе для решения задачи прогнозирования электропотребления;

3. Генерация начальных или исходных параметров;

4. Загрузка численных значений в сеть и инициация расчета;

5. Работа сети в соответствии с режимом обучения либо с фиксированным числом шагов, либо с переменным. При переменном количестве шагов выполняется минимизация ошибки. Т.е. настройка весов сети происходит таким образом, что отличие выходного сигнала от требуемого минимизируется.

6. Генерация решения.

Если сеть используется многократно, то первый и второй шаг в алгоритме не обязательны для повторения.

Распространенным подходом при проектировании ИНС является анализ и выбор структуры сети из созданных ранее шаблонов. К таким шаблонам могут относиться сеть Хопфилда, сеть Гросберга и сеть Кохонена. Учитывая тип решаемой задачи может быть выбран соответствующий шаблон. Для каждой конкретной задачи структура ИНС будет незначительно меняться. Изменения могут быть связаны в основном с изменением синаптических весов, способов обучения, способов представления входных и выходных данных.

Начальной точкой является формулировка задачи. Из формулировки происходит выбор конкретной сети, которая будет адекватная поставленной задаче. Выбор структуры происходит из существующих разработанных ранее. Но при выборе структуры следует учитывать, что типовая структура применима только к конкретной задаче. Исходя из этого обязательно необходимо выполнить настройку сети, без которой получение адекватных данных и точного решения будет менее вероятным.

1.6 Разомкнутые ИНС

При анализе разомкнутых ИНС обычно используют метод вероятностного анализа многомерных нелинейных систем. Использование данного метода обусловлено тем, что при его использовании полученные результаты не связаны со сложной структурой и разновидностью ИНС. Полученный результат - зависит от характеристик пространства признаков и пространства решений. Это свойство применяется для формирования функционала вторичной оптимизации ИНС и для создания замкнутых ИНС.

Функциональные возможности вторичной оптимизации ИНС - это выражаются параметрами распределения текущих сигналов и минимизируется в многослойными системами.

Рассмотрим проблемы синтеза. Первая проблема связана с необходимостью исследования соответствия функционала вторичной оптимизации ИНС с критерием первичной оптимизации. Примером может быть рассмотрение известных адаптивных структур: матрица Штайнбуха и трехслойный персептрон Розенблатта.

В качестве основного недостатка этого подхода выделим неопределённость критериев первичной оптимизации которые соответствуют функционалу вторичной оптимизации. Эта неопределенность показывает, что ряд систем могут стать неработоспособными из-за того что поступающие данные много модальные.

В качестве второй проблемы синтеза выделим проблему формирования функционала вторичной оптимизации. Т.е. соответствие функционала конкретному критерию первичной оптимизации. Под соответствием понимаем совпадение параметров ИНС при условии минимума функционалов вторичной и первичной оптимизации.

Разработано огромное количество структурных форм ИНС и каждая из них направлена и создана для решения конкретной задачи. Рассмотрим многослойную полно связанную ИНС прямого распространения входного

сигнала (рисунок 11). Основной функцией такой ИНС является распознавание и классификация образов. Полно связанная ИНС – это сеть в которой нейроны i -того слоя имеют связь со всеми нейронами $i+1$ слоя, первый слой связан со всеми входами ИНС. При прямом распространении данных в сети отсутствуют обратные петли. По обратным петлям данные, пройдя, через первый слой сети, могли бы вновь поступать на соответствующие входы.

Особенность сети заключается в ограниченных возможностях реализации разнообразных конфигураций разделяющих поверхности. Это выполняется из-за того, что нейрон не может реализовать булевскую функцию с $N > 2$ переменных. Если число нейронов во втором (скрытом) слое не ограничено, то для создания кусочно-линейной поверхности достаточно иметь 3 слоя искусственной нейронной сети.

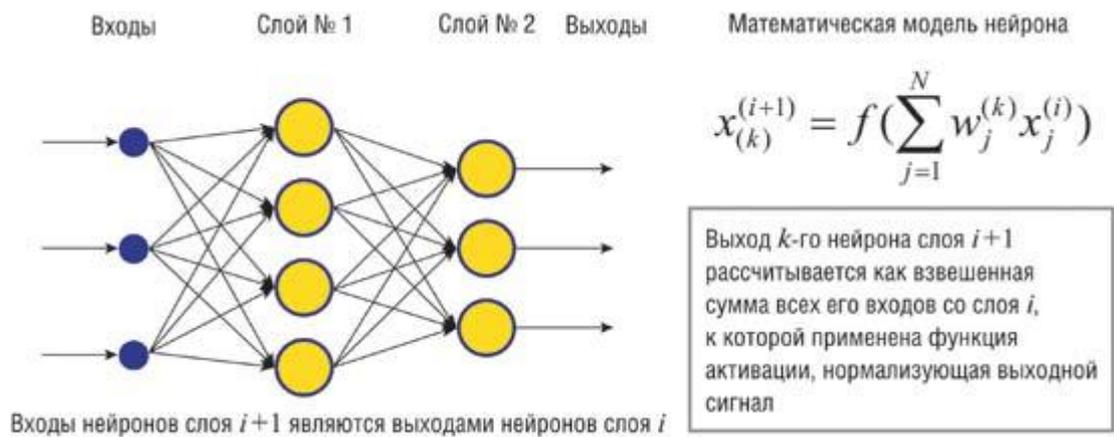


Рисунок 11 - Многослойная полно связанная ИНС прямого распространения сигнала

Для постановки задачи обучения необходим процесс, при котором функция, задаваемая «учителем», будет аппроксимирована автоматически по заданными свойствами. Задача самообучения может рассматриваться с точки зрения выделения функции распределения и распознавания образов на входе.

Объединение двух определений можно происходит при обучении ИНС «учителем» с заданными параметрами.

Сегодня растет популярность структурных методов исследования ИНС по сравнению с символическими. Так как ИНС имеют свойство многомерности, многослойности и многоконтурности, то данный метод исследования является наиболее актуальным. Такие свойства ИНС относятся больше к современным ИНС. Рассмотрим подробнее вопросы структурной оптимизации, т.е. вопросы повышение эффективности работы ИНС за счет применения структурных решений, а не за счет увеличения объема обучающих примеров. Для этого необходимо структурно описать преобразования разомкнутых ИНС.

1.7 Многослойные нейронные сети с перекрестными связями

$$y_n = F g_n = F \sum_{h_1=0}^{H_1} a_{h_1} y_{h_1} n = F \sum_{h_1=0}^{H_1} a_{h_1} F g_{h_1} n = F \sum_{h_1=0}^{H_1} a_{h_1} F \sum_{i=0}^N a_i x_i n \quad (12)$$

Многослойные ИНС с полно связанной структурой имеют большое количество признаков j -го слоя ($j=1, \dots, W$) они состоят из выходных сигналов от 1 до $(j-1)$, а так же к ним относятся и признаки исходного пространства.

Сравнение ИНС с полными перекрестными связями и с полными последовательными связями показывает, что сети полными перекрестными связями гораздо проще. Это объясняется меньшим количеством нейронов. Однако этот факт справедлив только в том случае, если структура разделяющих поверхностей у сетей одинакова.

Для ИНС с перекрестными связями будет справедливо следующее выражение (13):

$$y_n = F \sum_{h_1=0}^{H_1} a_{h_1} F \sum_{i=0}^N a_{ih_1} x_i(n) + \sum_{j=0}^N a_j x_j(n) \quad (13)$$

Графическая схема сети с перекрестными связями представлена на рисунке 12.

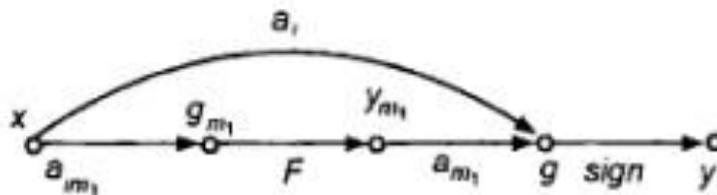


Рисунок 12 – Схема однослойной сети с перекрестными связями

Для двухслойной ИНС имеющую обратную связь справедливо выражения (14) и (15):

$$y_n = F(g(n)); g(n) = \sum_{h_1=0}^{H_1} a_{h_1} y_{h_1}(n) + a_k y(n-1) \quad (14)$$

$$y_{h_1}(n) = F(g_{h_1}(n)); g_{h_1}(n) = \sum_{i=0}^N a_{ih_1} x_i(n) + a y(n) + a_{h_1} y_{h_1}(n-1) \quad (16)$$

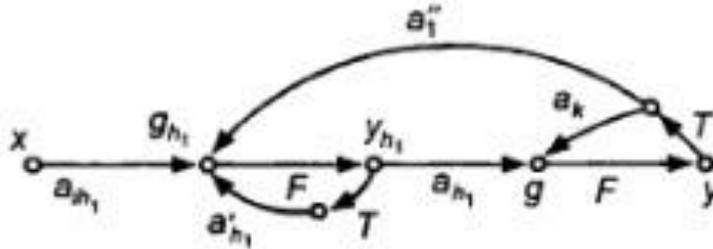


Рисунок 13 – Схема двуслойной сети с перекрестными связями

При сегодняшнем уровне развития технологий может быть реализована сеть, схема которой представлена на рисунке 14.

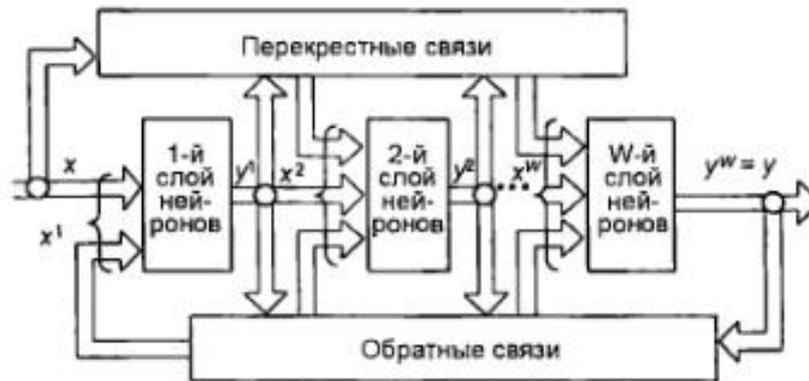


Рисунок 14 – Схема многослойной ИНС

1.8 Преимущества ИНС

Искусственные нейронные сети имеют ряд значительных преимуществ по сравнению с другими методами вычислений. К преимуществам ИНС можно отнести возможность параллельного вычисления в разы увеличивающее их мощность и самообучение, что может быть также выражено как создания обобщений. Обобщение – способность ИНС давать адекватное решение, за счет

использования данных встречающихся при обучении. Оба этих свойства делают ИНС мощным средством вычисления, которое может быть применимо при решении различных масштабных задач. Применение ИНС на практике показало, неспособность ИНС выдавать готовые решения если задача является многосоставной и сложной. Для решения подобного рода задач, требуется выполнить их разделение на более простые подзадачи и только после разделения подобрать соответствующую структуру ИНС.

Применение искусственных нейронных сетей позволяет получить некоторые полезные свойства системы. К таким свойствам относятся нелинейность, отображение входной информации в выходную, адаптивность, очевидность ответа, контекстная информация, устойчивость к недочётам, сверхвысокая интеграция, однородность анализа и синтеза, аналогия с нейробиологией. Рассмотрим более подробно каждое из этих свойств.

Нелинейность – свойство зависящее от вида искусственных нейронов. Нейроны либо линейны, либо нелинейны. Для случая нелинейности всех нейронов сети тоже будет называться нелинейной и нелинейность распределена по всей сети. Такие сети могут применяться для распознавания речи или других нелинейных сигналов.

Отображение входной информации в выходную. Наиболее эффективной парадигмой обучения является «обучение с учителем». Используя учебные примеры происходит изменения синаптических весов каждого нейрона и происходит перестроение нейронной сети в соответствии с учебными примерами. Обучающий пример состоит из исходного входного сигнала и желаемого отклика сети. Из большого числа обучающих примеров случайно выбирается один и ИНС выстраивает веса нейронов в соответствии с минимизацией отклонения выходного сигнала от требуемого.

Данный процесс может быть назван - модификация свободных параметров. При этом могут быть использованы вновь уже имеющиеся весовые коэффициенты, в случае если сеть достигает необходимых результатов

точности или вычисления повторяются. Обучение ИНС выполняется до того момента когда отличие выходного сигнала от требуемого минимизируется. В процессе обучения ИНС составляет таблицу, в которой для каждого входного сигнала существует выходной сигнал. Это делает обучение ИНС схожим с непараметрическим статистическим обучением. Непараметрический статический вид обучения работает с оценками. Термин «непараметрический» употребляется в смысле изначального отсутствия предопределенностей в связях входных и выходных сигналов.

Адаптивность. Как было отмечено ранее, ИНС имеют свойство адаптироваться при изменении внешних условий. Даже если обучение ИНС произошло в одних условиях внешней среды, а реальные условия отличаются, сеть не будет работать с ошибками. Сеть может быть переучена под новые условия работы. Однако существуют и нестационарные среды. Нестационарные среды - это среды в которых изменение внешних условий происходит в реальном времени. Существуют так же ИНС изменение весовых коэффициентов в которых происходит в реальном времени. Это типично для ИНС используемых для распознавания образов, задач управления и обработки сигналов. Подобные задачи связаны с адаптацией нейронных сетей. Таким образом можно получить адаптивные сети управления и адаптивные сети распознавания образов и входящих сигналов. Чем выше способность сети к адаптации, тем устойчивее она работает в изменяющейся среде. Однако способность к адаптации не всегда имеет положительное значение. Если сеть слишком чувствительна к изменениям внешней среды она может воспринять помехи как весомую часть входных данных, что может привести к растущей ошибке. Идеальным будет вариант который совмещает как способность к адаптации, так и стабильность сети, т.е. сети в которой основные параметры, оказывающие наибольшее влияние на выходной сигнал – стабильны, но в то же время в меру пластичны, для реагирования на сильные изменения

окружающего пространства. Такая задача получила название дилемма стабильности-пластичности.

Очевидность ответа. Искусственную нейронную сеть выполняющую задачи распознавания образов возможно обучить для определения достоверности принимаемого решения и после этого сеть может быть использована с сетями других типов. Это позволит повысить производительность синтезированной сети.

Контекстная информация. Применительно к ИНС контекстная информация это информация заложенная в самом состоянии нейронной сети. Нейронная сеть способна накапливать знания об окружающей среде благодаря состоянию ее активации, т.е. параметрам активации ее пороговых элементов. От параметров пороговых элементов зависит состояние активации. Поэтому работа нейронной сети связана с контекстной информацией.

Устойчивость к недочётам. Данный термин применительно к нейронной сети означает то, что производительность ИНС незначительно снижается при неблагоприятных условиях внешней среды. Этот факт относится в большей степени к тем сетям, которые на уровне электроники построены по принципу ИНС. Такое свойство проявляется вследствие того, что вся информация которую «запомнила» сеть распределена по ней равномерно. При повреждении одного нейрона или связей приостановит процесс извлечения информации из него, но при этом снижение производительности ИНС в целом будет происходить гораздо медленнее. Этот факт так же показывает, что обычно качество и точность работы ИНС снижается медленно. Различные незначительные повреждения сети вызывают малые отклонения. Это является безусловным преимуществом вычислений проводимых по принципам нечеткой логики. При проектировании ИНС в нее закладываются поправки позволяющие гарантировать данное свойство – устойчивость к недочетам.

Сверхвысокая интеграция. Параллелизм или исполнение вычислений одновременно либо совмещённо по времени, для ИНС обеспечивает ускорение

решения задач и дает возможность масштабирования ИНС. В данном случае понимается расширение структуры ИНС под решение более сложных задач. Масштабируемость происходит путем увеличения числа нейронов в сети, путем добавления в нее нейронов. Это свойство позволяет строить сложные, иерархические модели ИНС.

Однородность анализа и синтеза. Искусственные нейронные сети представляют собой универсальную структуру, позволяющую решать различные задачи. При этом одно и то же строение ИНС может использоваться для решения различных задач. Данное свойство проявляется следующим образом:

- составные части ИНС - нейроны, которые одинаковы по структуре;
- единообразие позволяющее использовать различные алгоритмы обучения для одних и тех же структур ИНС;
- возможность создания модульных сетей состоящих из нескольких подсетей.

Аналогия с нейробиологией. Нейронные сети построены подобно головному мозгу. Головной мозг – это огромная нейронная сеть обладающая способностью к быстрым и вычислениям и соответственно высокой мощностью. Мозг так же как и нейронная сеть, имеет способность к сохранению работоспособности при некорректной работе некоторых его частей. Поэтому нейробиологам интересны ИНС с точки зрения моделирования реальных физических явлений, а инженеры пытаются постоянно позаимствовать у нейробиологов новые идеи, которые выходят за рамки традиционных интегральных схем. Такие точки зрения демонстрируются на следующих примерах приведенных далее.

Модели линейных систем вестибуло-окулярного рефлекса (ВОР) могут быть сравнены с моделями рекуррентных нейронных сетей. Вестибуло-окулярный рефлекс (ВОР) – этот рефлекс является одной из частей глазодвигательной системы. В его задачи входит обеспечение стабильности

визуального образа при поворотах головы за счет вращения глаз. Вестибуло-окулярный рефлекс реализуется с помощью премоторных нейронов расположенных в вестибулярном центре. Полученные и обработанные ими сигналы поворота головы, приходящие от вестибулярных сенсорных нейронов, передаются на моторные нейроны глазных мышц. Вестибуло-окулярный рефлекс подходит для моделирования, так как входные и выходные сигналы, то есть сигналы поворота головы и глаз могут быть точно описаны. Кроме того ВОР - достаточно простой рефлекс и нейрофизические свойства нейронов, которые его реализуют хорошо и полно описаны. В вестибуло-окулярном рефлексе задействовано три типа нейронов. Одним из них являются премоторные. Эти нейроны входят в состав вестибулярного центра и являются самыми сложными. Этот факт делает данный тип нейронов наиболее интересным. Механизм ВОР ранее моделировался с использованием сосредоточенной линейной системы и теории управления. Данные модели могли описать только некоторые общие свойства однако они не давали полной картины понимания свойств свойствах самих нейронов. Появление нейросетевых моделей изменило текущую ситуацию. Рекурсивные модели ВОР позволили воспроизвести и описать большинство статических, динамических, нелинейных и распределенных аспектов обработки сигналов при реализации ВОР, а в частности описать вестибулярный центр.

Вторым примером можно привести сетчатку. Сетчатка выполняет функции визуальной связи окружающего мира с первым нейронным изображением. Сетчатка — это внутренняя оболочка, которая воспринимает свет. Для нашего случая мы можем описать сетчатку как матрицу состоящую из множества микроскопических рецепторов. Задачами сетчатки является преобразование входного визуального (оптического) сигнала в нейронное изображение. Нейронное изображение передается по оптическим нервам для анализа в различные центры. Учитывая тот факт, что сетчатка имеет синаптическую организацию — эта задача является для нее весьма сложной.

Преобразование любого входного изображения в сетчатке происходит в три этапа. На первом этапе происходит снятие фотоконии. Эта функция выполняется слоем нейронов-рецепторов. На втором этапе происходит передача уже сформированного сигнала на слой биполярных клеток. Данная передача осуществляется по химическим синапсам. И на третьем этапе, происходит еще одна передача, только уже на выходные нейроны. Передача третьего этапа так же как и вторая осуществляется по химическим синапсам.

На втором и третьем этапах в передаче участвуют нейроны с латеральным торможением и горизонтальные клетки. В задачу их входит осуществить преобразование сигнала между разными синаптическими слоями. Кроме того существуют центробежные элементы, которые передают полученный сигнал с внутреннего на внешний синаптический слой. Существует опыт создания электронных микросхем которые, имитируют структуру сетчатки. Такие электронные микросхемы получили название нейроморфные интегральные схемы (ИС). Нейроморфные ИС представляют матрицу фоторецепторов, которые связаны с соответствующими пикселями. Данные нейроморфные ИС имитируют сетчатку глаза в способности адаптации к изменению освещенности, идентификации контуров и движению. Нейробиологическая модель, воплощенная в нейроморфные ИС позволила обеспечить дополнительное преимущество связанное с физическим пониманием нейробиологических структур. Этот факт может оказать существенное влияние на развитие электроники и в частности на развитие технологии сверхвысокой интеграции.

Вывод по главе 1

В первой главе были рассмотрены существующие методы краткосрочно прогнозирования и определены альтернативные методы прогнозирования потребления энергосистемы Самарской области. Полностью раскрыта необходимость учета динамики изменения структуры потребителей энергосистемы для определения степени влияния метеорологических факторов. Результатом проделанного анализа является вывод о необходимости создания статистически-динамической модели потребления для энергосистемы Самарской области. Альтернативным вариантом должен быть рассмотрен вариант выполнения данной модели на основе искусственных нейронных сетей.

Применение искусственных нейронных позволит повысить оперативность формирования прогноза потребления, а также учесть динамические процессы происходящие в энергосистеме, которые влияют на характер потребления электрической энергии и мощности, что позволит повысить точность прогнозов.

2 Разработка статистическо-динамической модели потребления энергосистемы на базе искусственной нейронной сети

Для построения данной модели прогнозирования потребления энергосистемы, необходимо определить основные задачи: выбор программного продукта, на базе которого будет построена ИНС, из числа подходящих для решения задач при краткосрочном и оперативном прогнозировании, осуществить выбор архитектуры ИНС, сформировать статистические параметры при обучении ИНС, определить динамические параметры которые должны учитываться при формировании прогноза потребления.

При рассмотрении данных пунктов необходимо учитывать, что для решения поставленных задач могут быть использованы несколько вариантов.

Рассмотрим наиболее подходящие структуры построения ИНС и выберем оптимальный, для построения модели прогнозирования потребления по Самарской энергосистеме.

2.1 Выбор программного продукта для формирования модели прогнозирования ИНС

Для формирования краткосрочного и оперативного прогноза потребления электрической энергии могут быть использованы различные программные комплексы, в которых заложены статистические и нейросетевые математическо-аппаратные модели прогнозирования временных рядов.

Для рассмотрения выберем самые распространенные и часто используемые программные продукты для создания на базе ИНС моделей прогнозирования электропотребления.

Одним из распространенных таких программных комплексов является STATISTICA.

STATISTICA Automated Neural Networks – программный комплекс, разработанный компанией StatSoft для решения разнообразных задач, в

котором за счет использования ИНС с различной архитектурой и алгоритмами обучения обеспечивается довольно высокая точность формирования прогноза.

Преимуществами данного аппаратного комплекса являются:

- пользовательский интерфейс русифицирован;
- визуализация интерфейса выполнена на очень высоком уровне, обеспечивающая наглядность процесса создания, обучения и тестирования ИНС;
- наличие функции *Автоматизированная нейронная сеть (АНС)*, помогающая пользователю в короткий срок выбрать оптимальный вариант сети, исходя из требований при формировании прогноза, и позволяет исключить длительный поиск пользователем наилучшей модели путем «проб и ошибок»;
- возможность последовательного интегрирования целой цепочки ИНС без ограничений;
- создания собственных приложений для формирования прогноза потребления.

Но как и у любого программного продукты выполненного с высоким качеством, у данного продукта имеется недостаток, а именно высокая стоимость и необходимость длительного обучения специалиста для работы в данном комплексе. Поэтому создать необходимую модель в программном комплексе *STATISTICA Automated Neural Networks* не представляется возможным.

Необходимо отметить для рассмотрения следующий программный комплекс разработанный компанией MathWorks, а именно пакет прикладных программ MATLAB. Это один из самых широко применяемых программных комплексов для математического моделирования, которым пользуются инженеры всего мира. В состав данного комплекса входит пакет инструментов для математического моделирования ИНС Neural Network Toolbox, в котором имеются модули для создания и обучения ИНС.

Отметим очевидные преимущества данного пакета инструментов:

- разработчиками уже создано большое количество различных видов ИНС, что открывает неограниченные возможности для комбинирования и интерпретации различных ИНС пользователем в создании подходящей модели;
- свобода выбора соединения имеющихся блоков ИНС позволяет соединить их в необходимой последовательности исходя из необходимости создания архитектуры ИНС и метода обучения, что предопределяет возможность создания зависимостей определяющих конечный результат расчета. Своего рода гибкость;
- Возможность генерации исходного кода искусственной нейронной сети;
- Доступность программного комплекса, что делает данный комплекс одним из самых востребованных и удобных для пользователей во всем мире.

Необходимо обратить внимание на еще один комплекс FANN (Fast Artificial Neural Network), который может быть использован для формирования модели прогнозирования энергосистемы на основании ИНС. Он представляет собой открытое программное обеспечение для построения искусственных нейронных сетей. В данном комплексе предусмотрено множество языков программирования, которые позволяют формировать пользователю авторские модели на основе ИНС.

Его преимуществом является доступность, однако пользователю необходимо в совершенстве владеть языками программирования для успешного формирования различных моделей ИНС, что делает его доступным для работы узко квалифицированных специалистов владеющих навыками программирования, что существенно усложняет работу в данном комплексе.

Исходя из проведенного анализа по удобству и доступности программных комплексов, а самое главное по наличию инструментов неограничивающих в творческих и инженерных подходах и идеях, для формирования статистическо-динамической модели прогнозирования

потребления Самарской области на базе ИИС выбран комплекс MATLAB с пакетом инструментов Neural Network Toolbox.

2.2 Формирование статистической базы почасового потребления мощности энергосистемы

Для формирования качественного прогноза потребления мощности в энергосистеме на базе ИНС необходимо создавать статистические базы ретро-периода потребления электрической энергии и мощности достаточной глубины. Это вызвано необходимостью формирования в ИНС закономерностей и зависимостей, в виде коэффициентов, изменения траектории потребления в энергосистеме в зависимости от сезона года, рабочий или выходной день, долгота дня, события переносов выходных и праздничных дней, так как форма графика потребления в энергосистеме сильно отличается исходя из этих условий. Это объясняется тем, что несмотря на высокую долю крупных промышленных потребителей, коммунально-бытовая нагрузка существенно оказывает влияние на характер потребления, а долгота дня определяет доминирования утреннего или вечернего максимума. Это связано с тем, что население в своем большинстве работает на предприятиях и соответственно режим работы предприятий определяет потоки граждан в ту или иную сторону. При этом сам рабочий цикл предприятий и учреждений работают в одну смену по пятидневной рабочей неделе, соответственно режим работы данных предприятий определяет занятость и режим работы, как людей, так и режим работы производственного оборудования. В связи с этим, при прогнозировании потребления электрической энергии и мощности в энергосистеме вся неделя разбивается на характерные дня, т.е. если прогноз формируется на первый рабочий день, в основном это понедельник, то необходимо учитывать, что оборудование на многих предприятиях находилось в останове, и с началом первого рабочего дня оно будет пущено в работу, в связи с этим траектория потребления при переходе с воскресения на понедельник будет иметь в ночные часы минимальное значение, а с началом рабочего дня будет резко нарастать исходя из режима пуска оборудования из состояния останова.

Таким образом, рабочая неделя разбивается на следующие характерные периоды: первый рабочий день, середина недели, последний рабочий день, первый выходной, выходной перед первым рабочим днем.

Соответственно формированию закономерностей необходимо учитывать «жизненный цикл» потребителей в энергосистеме.

Особое внимание необходимо при обучении ИНС уделить метеофакторам влияющих на потребление в энергосистеме, основными для процесса обучения достаточно использовать данные о фактической ТНВ при фактическом потреблении мощности, а так же коэффициент облачности, так как косвенно облачность характеризует наличие осадков, а так же продолжительность светового дня с учетом сезонности года. Поэтому для составления модели использовалась база данных о ТНВ и облачности на каждый час суток ретро-периода почасового потребления энергосистемы Самарской области.

Исходя из требований к размерам статистических данных ретро-периода на основании которого необходимо обучить ИНС, достаточной глубиной является 3 года. В некоторых рассматриваемых автором работах утверждается, что наличие более глубокой базы данных способствует увеличению точности прогноза потребления. Это не совсем так, исходя из выше рассмотренной зависимости степени влияния электропотребления от ТНВ в таблице 1, можно сказать, что применение более глубоких данных за ретро период не повысит точность, так как характер потребления существенно изменился, если взять в сравнение 2007 год и 2016 год, поэтому для обучения ИНС необходимо использовать актуальные закономерности, в связи с этим для обучения ИНС была использована база статистических данных глубиной 5 лет.

Выше перечисленный объем данных для составления модели ИНС, обучения и работы данной модели является достаточным.

2.3 Адаптация входных данных для обучения искусственной нейронной сети

Для работы ИНС в среде MATLAB и обучения сети необходимо создать матрицу входных значений, которая должна иметь не менее 100 входных значений в одной строке. Поэтому была выполнена адаптация обучающих данных в соответствии с требованиями программного комплекса.

Так как краткосрочное и оперативное прогнозирование осуществляется на почасовое потребление мощности в энергосистеме в течении суток, то для решения задачи создания ИНС использовалась база данных с потреблением мощности на срез последней минуты часа, что соответствует деловым процессам при энергосистемы и регламентом ОРЭМ.

После пробных испытаний ИНС с использованием различных видов архитектуры ИНС на основании руководства пользователя MATLAB Neural Network Toolb, было установлено, что для обеспечения необходимой точности работы нейронной сети все имеющиеся данные о почасовом потреблении мощности должны быть приведены к виду:

$$P = 0;1 \quad (17)$$

где P – значения потребления мощности на срез последней минуты часа, МВт.

2.4 Выбор алгоритма обучения ИНС для статистическо-динамической модели

Входе процесса обучения ИНС, на первом этапе были выбраны два алгоритма, которые получили наиболее широкое распространение при обучении ИНС для прогнозирования с помощью временных рядов и были представлены в выбранном программном комплексе.

Алгоритм Левенберга-Марквардта первым использовался для формирования прогноза электропотребления, его суть заключается в

достижении среднеквадратической ошибки с минимальным значением. При достижении минимального значения ошибки, т.е. когда значение достигает минимального предела, обучение сети прекращается. Самыми очевидными достоинствами данного алгоритма является скорость обучения и низкая величина среднеквадратичной ошибки, которая может достигать минимального значения около $3,35E-05$, поэтому он был выбран на первоначальном этапе. В ходе испытаний данного алгоритма при формировании тестовых выборок было установлено, что величина ошибки прогнозирования выше, чем на предварительно созданной модели, на которой были проведены тестовые работы, поэтому при дальнейшем создании модели от данного алгоритма пришлось отказаться.

При дальнейшем рассмотрении других существующих алгоритмов прогнозирования, был выбран алгоритм, основанный на регуляризации Байеса.

По сравнению с алгоритмом Левенберга-Марквардта обучение модели занимает гораздо больше времени, но за счет достижения наименьшей среднеквадратической ошибки в результате изменение весов синаптических функций при достижении минимального значения ошибки при обучении, которая достигает порядка $2,02E-05$. В ходе испытаний данного алгоритма при формировании тестовых выборок было установлено, что величина ошибки прогнозирования на тестовой выборке становится меньше, в связи с этим на данном методе обучения был остановлен выбор, и для дальнейшего построения модели ИНС другие методы не рассматривались.

2.5 Выбор архитектуры ИНС для модели прогнозирования энергосистемы

Исходя из рассматриваемых вариантов обучения и формирования прогноза на первоначальном этапе исследования нужна была сеть ИНС, которая подбирала бы весовые коэффициенты таким образом, чтобы среднеквадратическое отклонение выходных значений от эталона было

минимальным, так как преимущество данного метода заключается в быстроте работы сети. Данному требованию подходила сеть прямого распространения данных и обратного распространения ошибки (Feed-forward backprop – далее FfB). На рисунке 15 показана схема данной сети. Такая архитектура сети требует ее обучения за счет задания целевых значений временного ряда, которые должны являться эталоном при формировании прогноза и входные данные, которые должны подлежать обработке.

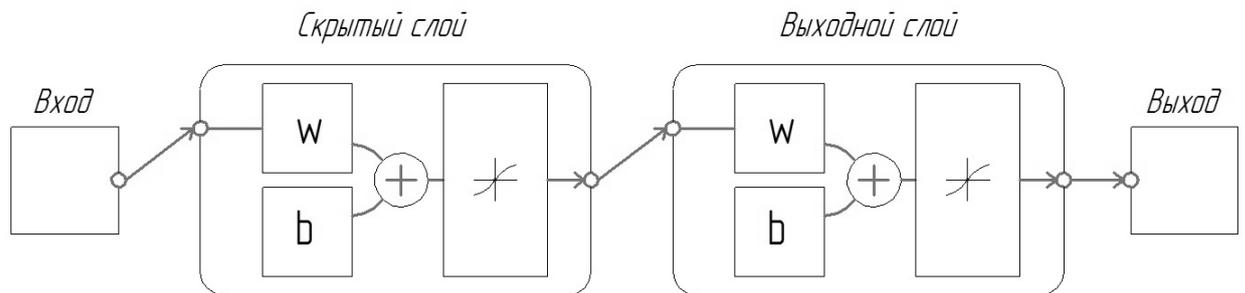


Рисунок 15 – Схема ИНС обратного распространения ошибки и прямого распространения данных

Из-за низкой точности и невозможности использования её для повторного обучения зависимостей полученных при первичном обучении сети, что является её неоспоримым недостатком для использования краткосрочного прогнозирования, то для дальнейшего рассмотрения была выбрана сеть с обобщенной рекуррентной архитектурой, которая построена на базе многослойного персептрона. Данная модель представлена на рисунке 16.

Суть работы данной модели заключается в наличии единственного входа, который на линиях задержки применяется к памяти, состоящей из q элементов. Замкнутый на вход через память на линиях задержки единственный выход, тоже состоит из q элементов. Для питания входного слоя персептрона используется содержимое этих двух блоков памяти.

Вход модели обозначается как $u(n)$, а выход — $y(n+1)$. Т.е. вход на одну единицу времени опережен выходом модели. Исходя из этого получается, что вектор сигнала, подаваемый на вход персептрона, состоит из окна данных, состоящего из следующих элементов:

- текущее и предыдущее значения входного сигнала, имеет вид сетей имеющие внешнее происхождение $u(n), u(n-1), \dots, u(n-q+1)$;

- значения выходного сигнала $y(n), y(n-1), \dots, y(n-q+1)$ в предшествующие моменты времени, от которых зависит выход модели $y(n+1)$.

Таким образом, рекуррентную сеть рассматривают как модель нелинейной авторегрессии с внешними входами. Динамику модели можно описать следующим уравнением:

$$y_{n+1} = F(y_n, \dots, y_{n-q+1}, u_n, \dots, u_{n-q+1}), \quad (16)$$

где F — некоторая нелинейная функция своих аргументов.

Для того чтобы задавать входные и целевые значения функции для модели ИНС необходимо использовать архитектуру с нелинейной авторегрессии, которая представлена на рисунке 17.

Что бы повысить точность работы сети ИНС необходимо, что бы данные на входе, проходя через сеть, обрабатывались в соответствии с весовыми коэффициентами, а затем снова попадали на вход сети, тем самым заменяя собой обратное распространение ошибки.

Применение архитектуры с нелинейной авторегрессии как раз дает возможность применения полученных после первичного обучения весовых коэффициентов при повторном обучении сети, что в свою очередь повышает точность ее работы.

Входе проведения тестовой выборке значение ошибки было ниже, чем в при обучении модели, это говорит о том, что обучении сети выполняется правильно.

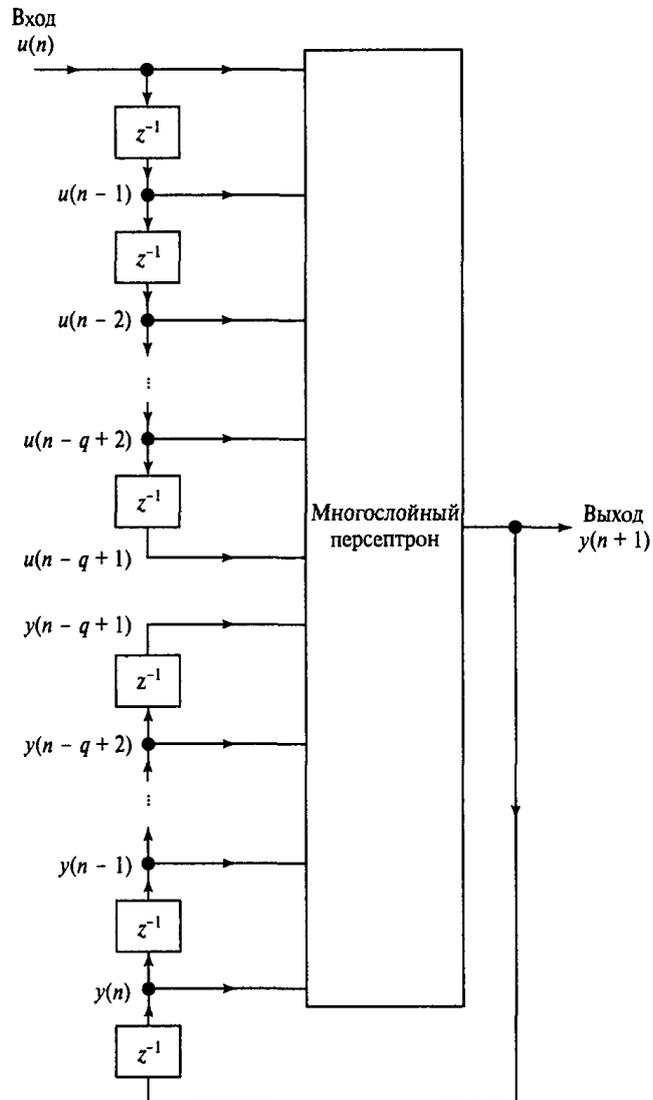


Рисунок 16 – Модель с внешними входами нелинейной авторегрессии

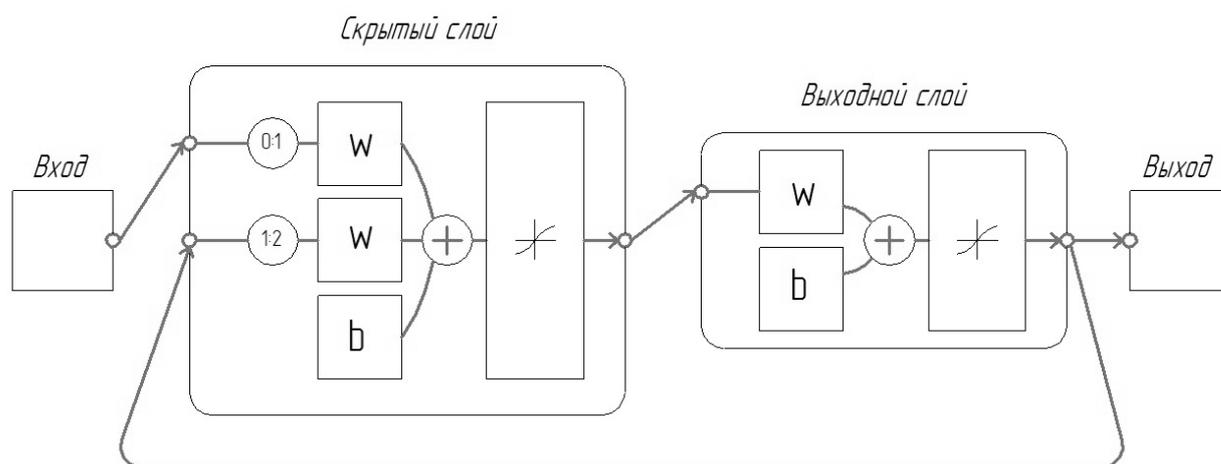


Рисунок 17 – Схема ИНС с внешними входами и нелинейной авторегрессии

2.6 Сравнение результатов прогнозирования при различных моделях построения ИНС

При исследовании моделирования процесса электропотребления в энергосистеме на первоначальном этапе была выбрана сеть, имеющая архитектуру прямого распространения данных и обратного распространения ошибки и обученная по алгоритму Левенберга-Марквардта (Feed-forward backprop).

Прогноз формировался для характерного рабочего зимнего дня 19 декабря 2016 г. При обучении сети были выбраны данные за ретро период глубиной 5 лет, которые были характерны для прогнозируемого дня исходя из требований описанные в п.2.2. данной работы.

Для объективности сравнения показателей качества прогнозирования при применении различных алгоритмов прогнозирования с использованием соответствующей архитектурой построения ИНС, необходимо было выбрать характерный один и тот же день, это позволило наиболее точно сравнить результаты полученных прогнозов.

По полученным результатам сравнения сформированного прогноза с использованием алгоритма обучения Левенберга-Марквардта и сети с прямым распространением данных и обратным распространением ошибки от

фактических значений, которые представлены на рисунке 14, исходя из полученного прогнозного графика потребления видно, что прогноз на 19 декабря выполнен с большей величиной ошибки, чем прогноз электропотребления на 20 декабря. При анализе полученных результатов было установлено, что из-за разности разброса данных для первого прогнозируемого дня и второго, за счет разности характера фактического потребления в ретро периоде в связи с резкими колебаниями ТНВ величина ошибки может сильно отличаться. При этом, стоит отметить, ИНС распознала закономерности построения графика нагрузки потребления в энергосистеме и траектория потребления похожа на фактическую траекторию потребления мощности, но точность потребления в час максимальных нагрузок оказалась очень низкой – 3,32% отклонений по модулю от объема потребления в час максимальных нагрузок, что в количественном выражении составило 245 МВт. Отклонение фактического потребления мощности от прогнозного для Самарской с величиной 245 МВт, является критичным, так как из-за такой ошибки при краткосрочном планировании для поддержания требуемых резервов мощности на электрических станциях для обеспечения компенсации потери наиболее крупной единицы генерирующего оборудования или сетевого элемента с учетом необходимости соблюдения ограничений перетоков мощности по контролируемым сечениям, в соответствии с СТО 59012820.27.010.007-2016 по результатам расчета ВСВГО будет пущено генерирующее оборудование с располагаемой мощностью 150 МВт, таким образом, результат ошибки приведет к излишним расходам на осуществление пусковых операций на ОРЭМ, а при фактическом наборе нагрузки данное оборудование будет не до загружено, а в ночное время приведет к необходимости останова в холодный резерв, что приведет к низкой эффективности данного мероприятия.

При рассмотрении результатов прогнозирования на 20 декабря, видно, что модель ИНС показала достаточно высокую степень точности – ошибка составила не более 2,33% от величины потребления мощности в час

максимума энергосистемы, что является приемлемым результатом. Необходимо отметить, что точность прогноза составленного специалистами выполняющими краткосрочный прогноз потребления не превышает в среднем не превышает 2%.

На следующем этапе исследования при изменении метода обучения и алгоритма прогнозирования ИНС была применена та же архитектура, что в первоначальном варианте. Принцип обучения, исходя из анализа рассматриваемых алгоритмов, был выполнен на основании регуляризации Байеса.

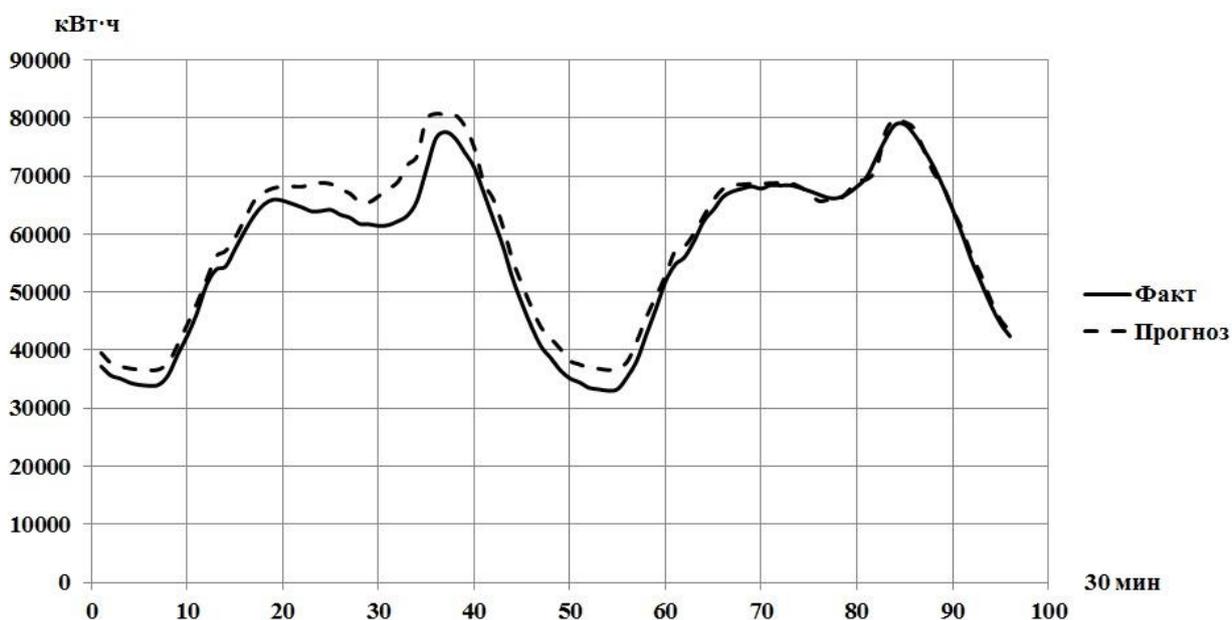


Рисунок 18 - Фактическое и прогнозное потребление энергосистемы Самарской области для 19 и 20 декабря 2016 года выполненное рассчитанные по алгоритму регуляризации Байеса на архитектуре модели FfB

Графики схожи с предыдущими, однако, стоит отметить, что точность составления прогноза в данном случае несколько выше, чем в предыдущем — она составила для 20 декабря 2,36% по модулю за операционные сутки. В абсолютном выражении это 85 МВт.

В ходе дальнейших работ по созданию модели прогнозирования Самарской энергосистемы была выбрана ИНС с иной архитектурой, на которой были опробованы те же алгоритмы обучения, что и на предыдущей модели.

ИНС построенная на архитектуре с внешними входами и нелинейной авторегрессии и имеет ряд особенностей в последовательности алгоритма обучения, суть которого составляет, что обучение проходит в два этапа. С начало происходит первичное определение весовых коэффициентов синаптических функций – это первый этап. Определение весовых коэффициентов происходит до тех пор, пока величина ошибки в обучаемой выборке данных не станет меньше величины в модели после завершения формирования прогноза, другими словами модель при обучении в рамках своего алгоритма, определяют весовые коэффициенты до тех пор, пока соотношение определенных зависимостей на основании входных данных не позволяет подобрать такую траекторию потребления, которая наиболее точно соответствовала траектории эталонного потребления (фактического потребления используемого для обучения модели). После того, как этот этап завершен, наступает второй этап обучения, на котором рассчитанные весовые коэффициенты на первоначальном этапе уточняются путем повторного обучения ИНС с учетом этих коэффициентов. Эта особенность данного алгоритма обучения позволяет достичь минимального отклонения прогнозных значений от фактических значений потребления мощности в энергосистеме.

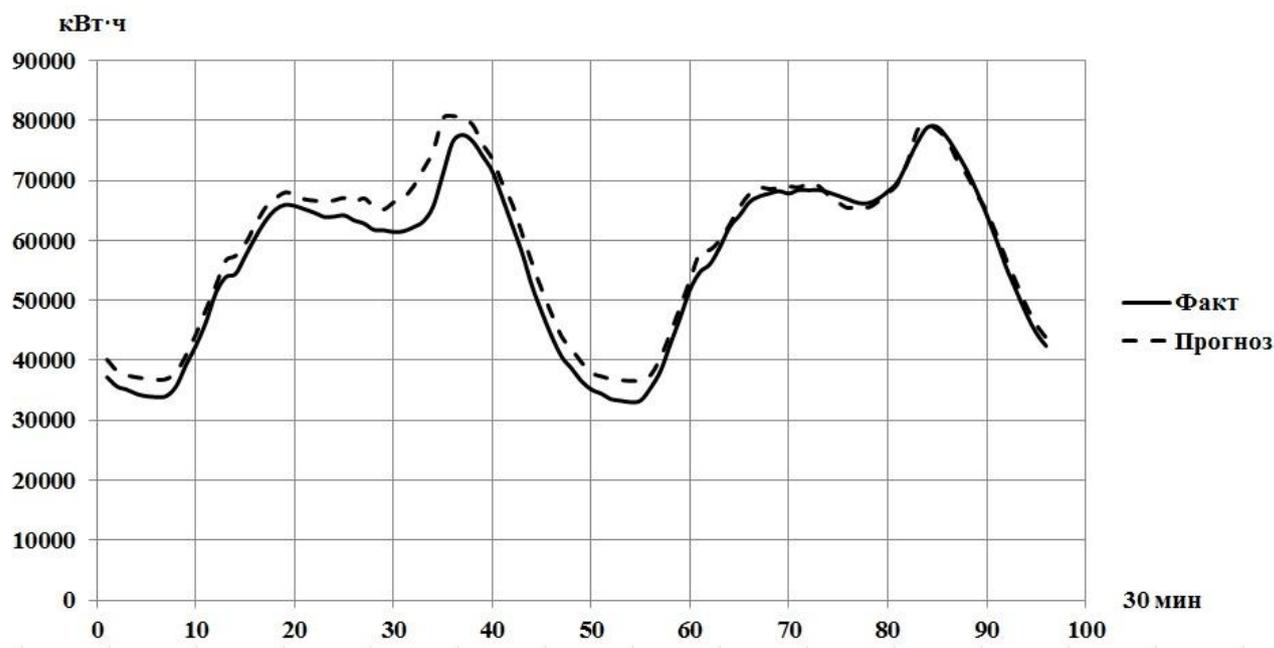


Рисунок 19 – Фактическое и прогнозное потребление энергосистемы Самарской области для 19 и 20 декабря 2016 года выполненное по алгоритму обучения Левенберга-Марквардта

Учитывая особенность ИНС на архитектуре было проведено обучение по алгоритму Левенберга-Марквардта, в результате при использовании полученной модели ИНС для прогнозирования электропотребления на 19 и 20 декабря 2016 года были полученные следующие результаты точности прогнозирования: отклонение по модулю в процентном соотношении в час максимального потребления мощности в энергосистеме составило 5,88% или 205 МВт. Такой результат является неприемлемым, но необходимо отметить, что при дальнейшем обучении данной ИНС за счет особенностей архитектуры можно достичь снижения величины ошибки. Это является как плюсом, так и недостатком, что исключает возможность рассмотрения данной ИНС в прикладных задачах краткосрочного прогнозирования потребления в энергосистемах.

Недостатком постоянного уточнения весовых коэффициентов являются следующее, при формировании прогноза потребления на первый день прогнозируемого периода, к примеру X-2, модель в особенности своей

архитектуры и алгоритма обучения формирует прогноз на день X-2, при этом набор данных для данного имеет больший разброс, как в случаи 19 декабря. При формировании прогноза на X-3, что соответствовало 20 декабря, из-за схожести эталонных графиков потребления статистических данных ретро периода, весовые коэффициенты 19 декабря были применены на 20 декабря, и в соответствии с особенностями алгоритма были уточнены (пересчитаны) весовые коэффициенты синоптических функций, т.е. модель ИНС была излишне переобучена, что привело к увеличению ошибки сформированного прогноза на 20 декабря, которая составила 2,43%.

Последним из предлагаемых вариантов построения ИНС была выбрана на основании архитектуры с алгоритмом обучения на основании формы отбора допустимых решений при построении устойчивых к исходной информации приближенных решений неопределенно поставленных задач (регуляризация) по принципу Бейза.

Эта модель рассматривается как наиболее перспективная для дальнейшего использования при прогнозировании потребления в энергосистемах, так как и принцип обучения и архитектура сети и направлены на поиск весовых коэффициентов, позволяющих с наибольшей достоверностью осуществлять прогнозирование временных рядов.

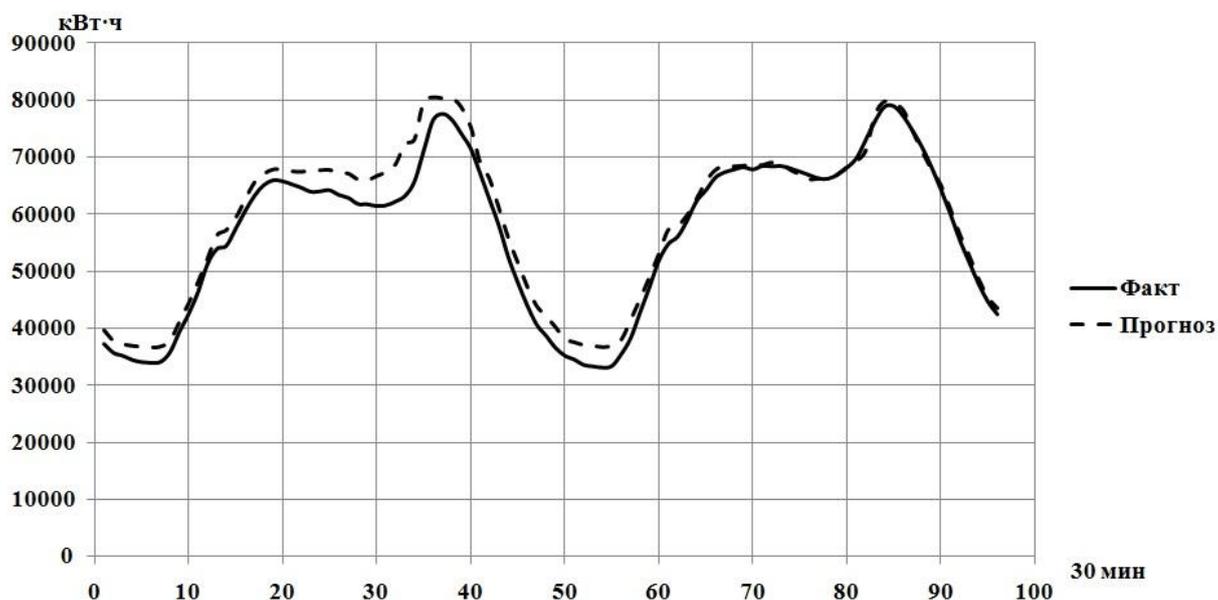


Рисунок 20 - Фактическое и прогнозное потребление энергосистемы Самарской области для 19 и 20 декабря 2016 года выполненное по алгоритму обучения регуляризация Байеса на архитектуре

Также как и в предыдущих вариантах для объективной оценки сравнения качества формируемых прогнозных значений почасового потребления мощности в энергосистеме прогноз был выполнен для двух рабочих дней декабря 19-20 декабря 2016г.

Как видно из рисунка 17, принципиальных различий с предыдущими прогнозными графиками особо не выделяются, но в данном случае достигнута максимальная точность прогнозирования за 20 декабря.

Таблица 2- Результаты

Часы	Период								
	X-4	X-2'	РСВ	X-1	факт	отклонения от факта, %			
						X-4	РСВ	X-2	X-1
1	2	3	4	5	6	7	8	9	10
1	2607	2598	2598	2596	2569	-1,45	-1,13	-1,13	-1,02
2	2547	2555	2555	2563	2553	0,26	-0,07	-0,07	-0,35
3	2569	2555	2555	2570	2549	-0,77	-0,24	-0,24	-0,84
4	2610	2605	2605	2602	2625	0,57	0,77	0,77	0,88
5	2726	2721	2721	2724	2733	0,26	0,44	0,44	0,33
6	2954	2947	2947	2938	2943	-0,39	-0,15	-0,15	0,16
7	3158	3131	3131	3121	3125	-1,05	-0,18	-0,18	0,12

Продолжение таблицы 2

1	2	3	4	5	6	7	8	9	10
8	3224	3218	3218	3215	3164	-1,90	-1,71	-1,71	-1,60
9	3272	3254	3254	3250	3193	-2,48	-1,89	-1,89	-1,78
10	3186	3183	3183	3180	3129	-1,83	-1,75	-1,75	-1,64
11	3172	3170	3170	3166	3151	-0,68	-0,61	-0,61	-0,50
12	3162	3195	3195	3191	3127	-1,13	-2,16	-2,16	-2,05
13	3195	3202	3202	3199	3152	-1,37	-1,60	-1,60	-1,49
14	3176	3172	3172	3168	3136	-1,28	-1,14	-1,14	-1,03
15	3191	3185	3185	3182	3126	-2,07	-1,88	-1,88	-1,77
16	3302	3249	3249	3257	3187	-3,62	-1,95	-1,95	-2,21
17	3303	3303	3303	3286	3195	-3,39	-3,40	-3,40	-2,85
18	3259	3243	3243	3240	3161	-3,11	-2,62	-2,62	-2,51
19	3185	3169	3169	3166	3096	-2,86	-2,36	-2,36	-2,25
20	3168	3148	3148	3145	3056	-3,67	-3,04	-3,04	-2,93

21		3078	3040	3040	3037	2941	-4,64	-3,35	-3,35	-3,24
22		2847	2867	2867	2860	2799	-1,70	-2,42	-2,42	-2,17
23		2729	2728	2728	2725	2664	-2,45	-2,43	-2,43	-2,32
24		2647	2638	2638	2636	2582	-2,51	-2,18	-2,18	-2,07
сумма		72266	72078	72078	72016	70955				
max	МВт	3303	3303	3303	3286	3195	-3,39	-3,40	-3,40	-2,27

Результаты полученных расчетов точности прогнозирования на различных этапах сведены в таблицу 2.

Ошибка составила 2,27% от в час максимального потребления мощности в энергосистеме или 91 МВт в абсолютном выражении. Данный результат можно считать удовлетворительным, при такой ошибке при краткосрочном планировании для поддержания требуемых резервов мощности на электрических станциях для обеспечения компенсации потери наиболее крупной единицы генерирующего оборудования или сетевого элемента с учетом необходимости соблюдения ограничений перетоков мощности по контролируемым сечениям, в соответствии с СТО 59012820.27.010.007-2016 по результатам расчета ВСВГО излишнее генерирующее оборудование не будет включено, так как отклонение составляет не больше величины не регулярных колебаний при учете резервов РТР и РПР на этапе расчета.

Таким образом, результат является очень приемлемым даже в сравнении с составленным прогнозом на эвристическом методе. Можно говорить о том, что такой вариант модели искусственной нейронной сети является оптимальным.

Вывод по главе 2

По результатам 2 главы был выбран оптимальный программно-аппаратный комплекс Matlab, который имеет множество инструментов для построения и реализации ИНС. Исходя из широких возможностей и предлагаемых готовых решений в данном программном комплексе был произведен анализ выбора архитектуры ИНС и алгоритм ее обучения. На основании собранных моделей ИНС выполнено тестирование различных вариантов. На основании полученных результатов выбрана оптимальная архитектура сети с наиболее подходящим алгоритмом обучения ИНС исходя из требований учитываемых параметров и закономерностей. В ходе тестирования было установлено, что наиболее приближенный вариант прогноза потребления в энергосистеме к фактическому достигается за счет применения ИНС выполненная на основании нелинейной авторегрессией с алгоритмом обучения Байеса. Полученная модель была выбрана для дальнейшего исследования.

3 Введение в модель прогнозирования сведений о метеофакторах, влияющих на характер электропотребления

3.1 Оценка качества прогнозирования модели ИНС на различных типах данных

Для определения корректности построения ИНС было проведено тестирование с использованием различных типов графиков. В данной работе п.2.2. было определено, что траектория графика потребления мощности в энергосистеме зависит не только от метеоусловий, сезона года. Но и от характера дня: рабочий/выходной, первый рабочий или первый выходной, рабочий день перед первым выходным днем или выходной день перед первым рабочим днем. Для данных характерных дней, суточные графики потребления в энергосистеме, с учетом сезонности метеорологических факторов существенно отличаются друг от друга. Таким образом, проверка корректности формирования ИНС с учетом вышеуказанных зависимостей, является хорошим испытанием способности распознавания закономерностей в рядах данных и наглядно покажет, насколько способна перестраиваться ИНС, в связи с изменениями характера данных.

Для испытания был взят, в противовес предыдущему характерному дню зимнего месяца, первый выходной и выходной перед рабочим днем летнего месяца, а именно 18 – 19 июня, так как характер потребления в данные дни существенно отличается характера потребления в отопительный период, или как его еще называют осенне-зимний период (ОЗП).

Необходимо учитывать, что при прогнозировании потребления мощности в энергосистемах особое внимание уделяется потреблению мощности на час прохождения максимальных нагрузок, так называемые пиковые часы. Так как, в пиковые часы спрос на электрическую энергию самый высокий, что в свою очередь накладывает нагрузку на энергосистему и оборудование электросетевого комплекса.

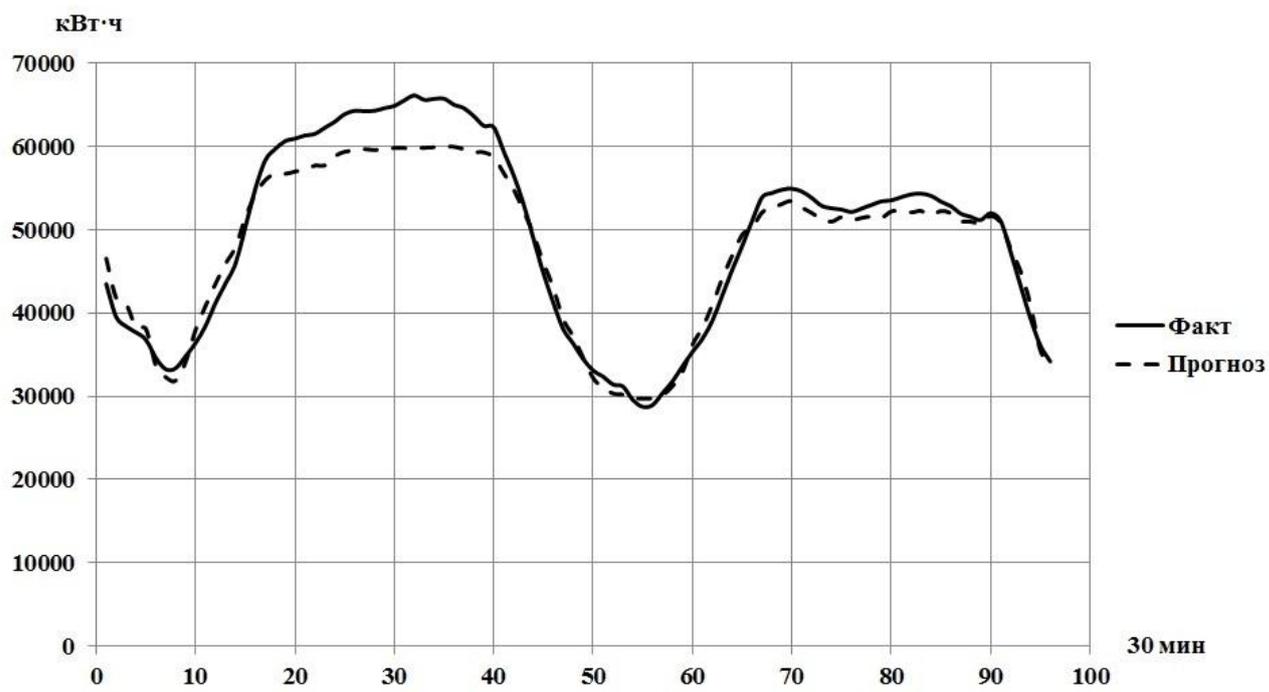


Рисунок 18 - Фактическое и прогнозное потребление энергосистемы Самарской области для 14 и 15 июня 2016 года выполненное по алгоритму обучения регуляризация Байеса на архитектуре NARX

Пиковые часы в период ОЗП и в летний период, его еще называют период экстремально-высоких температур (далее – ПЭВТ), отличаются это связано как с продолжительностью светового дня, в период ПЭВТ оно существенно выше, чем в период ОЗП, так и с ТНВ и соответственно составом потребителей энергосистемы, в летний период это климатические системы, которые основную нагрузку несут в часы пиковых летних температур, которые приходятся на дневное время, а в зимний период существенную долю составляют насосы системы централизованного отопления, которые основную нагрузку испытывают в период низких температур, в основном это ночное время.

После проведенного обучения и формирования прогнозных графиков потребления мощности в энергосистеме было установлено, что отклонение за 14 июня 2016г в процентном соотношении в час максимального потребления за

сутки составило 5,43%. В абсолютном выражении отклонение максимума потребления от прогнозного составило 101 МВт в операционных сутках.

Таблица 3 – Результаты сравнения прогнозной величины от фактической

Период прогнозирования					
Часы	X-2	X-1	факт	Отклонение в %	
				X-2	X-1
1	2227	2207	2206	-0,94	-0,06
2	2167	2157	2130	-1,70	-1,28
3	2119	2110	2122	0,18	0,56
4	2116	2111	2143	1,26	1,51
5	2230	2216	2180	-2,24	-1,64
6	2390	2376	2316	-3,11	-2,51
7	2596	2575	2525	-2,76	-1,96
8	2750	2745	2662	-3,22	-3,04
9	2842	2843	2760	-2,89	-2,93
10	2820	2815	2723	-3,44	-3,29
11	2841	2849	2746	-3,32	-3,59
12	2858	2861	2723	-4,70	-4,82
13	2846	2855	2707	-4,89	-5,17
14	2814	2824	2660	-5,48	-5,80
15	2770	2782	2610	-5,77	-6,18
16	2728	2738	2543	-6,81	-7,13
17	2688	2693	2511	-6,61	-6,78
18	2644	2651	2466	-6,72	-6,97
19	2581	2573	2411	-6,62	-6,33
20	2623	2615	2469	-5,88	-5,58
21	2658	2644	2510	-5,56	-5,06
22	2526	2507	2373	-6,05	-5,35
23	2363	2346	2233	-5,50	-4,79
24	2229	2212	2121	-4,83	-4,13
Сумма		61426	61306	58849	
max	МВт	2858	2861	2760	-5,43
	час	12	12	9	

За 15 июня 2016г. отклонения в процентном соотношении по модулю в час максимального потребления за сутки составило 2,55%. и в абсолютном выражении отклонение составило 70,4 МВт.

Данный результат можно считать удовлетворительным, хотя необходимо совершенствовать обучение данной модели, так при такой ошибке при краткосрочном планировании для поддержания требуемых резервов мощности

на электрических станциях для обеспечения компенсации потери наиболее крупной единицы генерирующего оборудования или сетевого элемента с учетом необходимости соблюдения ограничений перетоков мощности по контролируемым сечениям, в соответствии с СТО 59012820.27.010.007-2016 по результатам расчета ВСВГО в период ПЭВТ может быть включено в работу, так как отклонение составляет больше величины нерегулярных колебаний при учете резервов РТР и РПР на этапе расчета ВСВГО.

Но так как распознавание формы графиков происходит верно, соответственно необходимо продолжить совершенствование данной модели.

Необходимо обратить внимание, что величина отклонения (ошибки) на первый прогнозный день выше, чем во втором, это можно объяснить особенностью обучения искусственной нейронной сети. Исходя из специфики обучения, можно сделать вывод, что к концу временного периода веса синаптических функций при обучении принимают оптимальные значения, нежели в начале процесса обучения. Поэтому к концу временного периода происходит снижение ошибки прогнозирования. Данная проблема не является критической для краткосрочного и оперативного прогнозирования, так как составление краткосрочного прогноза происходит на четверо суток вперед сутки вперед и прогноз на последний день 4х дневного периода не влияет на качества результатов расчета ВСВГО, а для повышения точности прогнозирования, в качестве исходных данных, для принятия оптимального значения веса синаптических функций, будут использоваться данные оперативного прогноза потребления в день, в котором происходит формирование краткосрочного прогноза.

3.2 Оценка эффективности введения в прогнозную модель данных влияющих на динамику потребления в энергосистеме

На основании данных приведенных в первой главе было установлено, что зависимость потребления в энергосистемах определяется структурой

потребления потребителей и в зависимости от соотношения промышленных потребителей и коммунально-бытовой нагрузки определяется степень влияния потребления в энергосистеме от различных факторов.

Все факторы влияющие на потребление в энергосистеме описаны в первой и во второй главе, в связи с этим нет необходимости описывать все сложные воздействия внешней среды оказывающих влияние на траекторию потребления в энергосистемах, однако стоит отметить, что одним из множества факторов можно выделить, несколько самых сильных по оказанию воздействия на график потребления мощности в энергосистеме – это температура наружного воздуха (ТНВ), характер или статус дня, время года, более конкретно, отопительный сезон или период ПЭВТ и облачность, что в свою очередь косвенным путем предопределяет наличие осадков и изменение длительности светового дня.

Поэтому в создании статистическо-динамической модели энергосистемы выполненной на базе ИНС, для учета данных факторов, было сделано следующее:

- характер дня был обозначен следующим образом: 1 – первый рабочий день после выходного; 2 – рабочие дни среди недели (вторник, четверг, пятница), 3 – последний рабочий день перед первым выходным днем (пятница), 4- первый выходной день после рабочего дня (суббота), 5 – последний выходной день перед рабочим днем (воскресенье), 6 – выходной праздничный день в середине цикла выходных-праздничных дней.

- облачность: 1 – ясно, коэффициент 0; 2 – небольшая облачность, коэффициент 0,2-0,3; 3 –облачность, коэффициент 0,4-0,6; 4 – местами осадки , коэффициент 0,7-0,8; облачность; 5 – осадки, коэффициент 0,9-1,0.

- фактическая ТНВ вносилась в базу данных для каждого часа суток, соответствующему конкретной величине потребления мощности в энергосистеме.

3.3 Оценка эффективности прогнозирования выбранной модели нейронной сети с возможностью учета метеофакторов

Для того чтобы при прогнозировании в модели ИНС учитывались метеофакторы, необходимо исходную архитектуру ИНС нелинейной авторегрессии видоизменить, таким образом, чтобы архитектура позволяла производить параллельные вычисления одновременно нескольких параметров, что и требовалось при постановки задачи. На рисунке 20 представлена архитектура ИНС с нелинейной авторегрессии и возможностью параллельных вычислений.

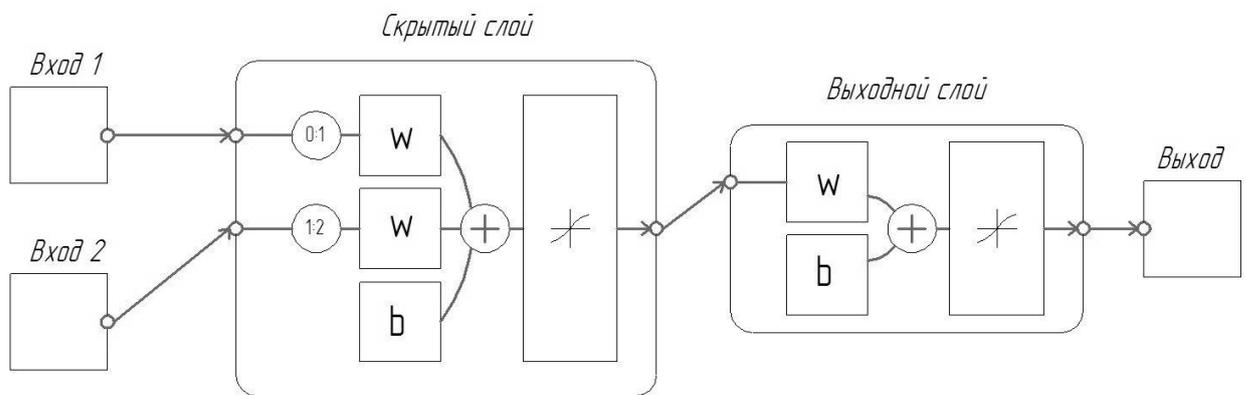


Рисунок 20 – модель ИНС с нелинейной авторегрессии и возможностью параллельных вычислений

Результаты вычислений проведённые модели представленной на рисунке 20 представлены на рисунке 21.

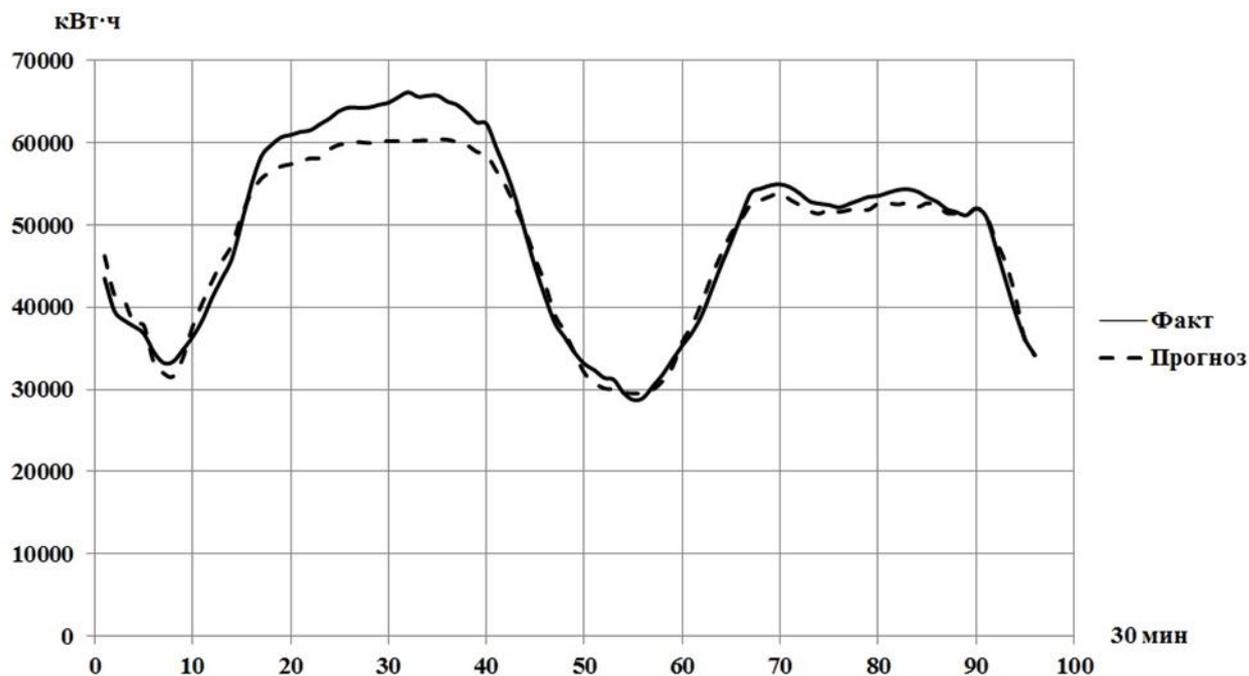


Рисунок 21 - Фактическое и прогнозное потребление энергосистемы Самарской области для 14 и 15 июня 2016 года алгоритм регуляризация Байеса, с возможностью параллельных вычислений

На рисунке 21 представлены прогнозный и фактический графики потребления мощности в энергосистеме в Самарской области для 14 и 15 июня 2016 года. Результаты можно считать удовлетворительными, так как в процентном соотношении в час максимальных нагрузок ошибка для 14 июня составила 5,14%, что в абсолютном выражении составило 140 МВт.

Для 15 июня по тем же параметрам ошибка составила 1,82% в час максимальных нагрузок ошибка. Абсолютное отклонение составило 49 МВт, что не превышает величину нерегулярных колебаний при определении резервов РТР и РПР по результатам расчета ВСВГО в соответствии с СТО 59012820.27.010.007-2016.

Так же на основании полученной модели для определения влияния сезонности на качество прогнозирования были выполнены тестовые расчеты для соответствующих сезонов. Все расчетные и аналитические показатели были занесены в таблицы 4-10

Таблица 4 – Результаты сравнения прогнозной величины от фактической в характерный день периода ПЭВТ

Период прогнозирования 25.07.2016, первый рабочий день после выходного										
Часы	X-4	X-2'	X-2	X-1	факт	отклонения от факта, %				
						X-4	X-2'	X-2	X-1	
1	1953	1953	1953	1995	2056	5,29	5,30	5,30	3,09	
2	1893	1893	1893	1959	1983	4,73	4,74	4,74	1,22	
3	1860	1860	1860	1934	1968	5,82	5,82	5,82	1,75	
4	1863	1863	1863	1913	1921	3,10	3,12	3,12	0,43	
5	1953	1953	1953	2016	2014	3,11	3,13	3,13	-0,09	
6	2100	2100	2100	2157	2158	2,78	2,78	2,78	0,06	
7	2266	2266	2266	2313	2297	1,34	1,35	1,35	-0,71	
8	2388	2388	2388	2460	2446	2,39	2,41	2,41	-0,58	
9	2470	2470	2470	2525	2548	3,19	3,18	3,18	0,95	
10	2447	2447	2447	2508	2580	5,42	5,44	5,44	2,86	
11	2446	2446	2446	2484	2597	6,16	6,17	6,17	4,54	
12	2429	2429	2429	2498	2559	5,33	5,34	5,34	2,43	
13	2425	2425	2425	2526	2598	7,12	7,11	7,11	2,82	
14	2418	2418	2418	2489	2594	7,25	7,26	7,26	4,18	
15	2414	2414	2414	2480	2540	5,26	5,24	5,24	2,43	
16	2384	2384	2384	2443	2516	5,53	5,53	5,53	2,97	
17	2351	2351	2351	2425	2503	6,46	6,47	6,47	3,23	
18	2323	2323	2323	2386	2426	4,44	4,42	4,42	1,65	
19	2310	2310	2310	2362	2412	4,40	4,42	4,42	2,14	
20	2358	2358	2358	2418	2472	4,84	4,85	4,85	2,23	
21	2389	2389	2389	2451	2503	4,74	4,76	4,76	2,10	
22	2262	2262	2262	2299	2345	3,65	3,68	3,68	2,01	
23	2142	2142	2142	2167	2150	0,37	0,39	0,39	-0,78	
24	2036	2036	2036	2054	2119	4,04	4,06	4,06	3,12	
сумма	53884	53880	53880	55264	56305					
max	МВт	2470	2470	2470	2526	2598	5,17	5,16	5,16	2,82
	час	9	0	0	13	13				

Таблица 5 – Результаты сравнения прогнозной величины от фактической

Период прогнозирования 23.10.2016 второй рабочий день-середина недели									
Часы	X-4	X-2'	X-2	X-1	факт	отклонения от факта, %			
						X-4	X-2'	X-2	X-1
1	2383	2383	2383	2381	2337	-1,92	-1,92	-1,92	-1,85
2	2351	2351	2351	2352	2305	-1,95	-1,95	-1,95	-2,01
3	2343	2343	2343	2332	2302	-1,75	-1,75	-1,75	-1,28
4	2353	2353	2353	2353	2332	-0,91	-0,91	-0,91	-0,91

5	2398	2398	2398	2389	2339	-2,43	-2,43	-2,43	-2,10
---	------	------	------	------	------	-------	-------	-------	-------

Продолжение таблицы 5

6	2427	2427	2427	2431	2420	-0,30	-0,30	-0,30	-0,48	
7	2503	2503	2503	2476	2433	-2,78	-2,78	-2,78	-1,74	
8	2607	2607	2607	2599	2601	-0,20	-0,20	-0,20	0,09	
9	2659	2659	2659	2654	2682	0,85	0,85	0,85	1,03	
10	2668	2668	2668	2667	2693	0,93	0,93	0,93	0,97	
11	2677	2677	2677	2680	2707	1,11	1,11	1,11	0,99	
12	2673	2673	2673	2675	2715	1,57	1,57	1,57	1,51	
13	2670	2670	2670	2685	2722	1,93	1,93	1,93	1,37	
14	2665	2665	2665	2657	2708	1,59	1,59	1,59	1,89	
15	2678	2678	2678	2668	2743	2,40	2,40	2,40	2,81	
16	2708	2708	2708	2715	2767	2,19	2,19	2,19	1,93	
17	2825	2825	2825	2859	2951	4,47	4,47	4,47	3,23	
18	2891	2891	2891	2885	2960	2,39	2,39	2,39	2,59	
19	2854	2854	2854	2844	2885	1,08	1,08	1,08	1,42	
20	2815	2815	2815	2816	2860	1,58	1,58	1,58	1,56	
21	2707	2707	2707	2716	2747	1,45	1,45	1,45	1,12	
22	2582	2582	2582	2569	2592	0,39	0,39	0,39	0,89	
23	2477	2477	2477	2483	2509	1,28	1,28	1,28	1,03	
24	2384	2384	2384	2412	2436	2,20	2,20	2,20	1,00	
сумма	62297	62297	62297	62300	62744					
max	МВт	2891	2891	2891	2885	2960	2,39	2,39	2,39	2,59
	час	0	0	0	0	0				

Таблица 6 – Результаты сравнения прогнозной величины от фактической

Период прогнозирования 17.10.2016 начало отопительного сезона									
Часы	X-4	X-2'	X-2	X-1	факт	отклонения от факта, %			
						X-4	X-2'	X-2	X-1
1	2342	2341	2341	2339	2318	-1,03	-0,97	-0,97	-0,89
2	2325	2322	2322	2331	2285	-1,73	-1,58	-1,58	-1,97
3	2320	2315	2315	2304	2307	-0,59	-0,37	-0,37	0,12
4	2366	2360	2360	2354	2358	-0,33	-0,07	-0,07	0,17
5	2495	2502	2502	2487	2477	-0,75	-0,99	-0,99	-0,43
6	2690	2695	2695	2689	2676	-0,54	-0,70	-0,70	-0,51
7	2848	2865	2865	2878	2857	0,30	-0,28	-0,28	-0,74
8	3014	3018	3018	3019	2953	-2,02	-2,17	-2,17	-2,19
9	3088	3081	3081	3074	2986	-3,33	-3,10	-3,10	-2,87
10	3033	3034	3034	3026	2899	-4,40	-4,43	-4,43	-4,21
11	3013	3016	3016	3028	2922	-3,03	-3,13	-3,13	-3,51
12	3026	3022	3022	3011	2916	-3,65	-3,50	-3,50	-3,18
13	3013	3033	3033	3020	2923	-2,98	-3,63	-3,63	-3,21
14	2949	2984	2984	2976	2897	-1,74	-2,92	-2,92	-2,63
15	2924	2949	2949	2942	2915	-0,32	-1,14	-1,14	-0,91

Продолжение таблицы 5

16	2908	2940	2940	2922	2908	-0,01	-1,10	-1,10	-0,50	
17	3008	3001	3001	3013	3029	0,70	0,91	0,91	0,51	
18	3111	3091	3091	3091	3025	-2,78	-2,14	-2,14	-2,14	
19	3048	3035	3035	3017	2960	-2,88	-2,45	-2,45	-1,87	
20	3024	3003	3003	2992	2915	-3,60	-2,94	-2,94	-2,56	
21	2886	2875	2875	2870	2803	-2,89	-2,52	-2,52	-2,33	
22	2722	2702	2702	2696	2643	-2,90	-2,20	-2,20	-1,96	
23	2583	2583	2583	2567	2503	-3,10	-3,10	-3,10	-2,49	
24	2486	2490	2490	2493	2435	-2,02	-2,20	-2,20	-2,32	
сумма	67224	67258	67258	67140	65909					
max	МВт	3111	3091	3091	3091	3029	-2,65	-2,00	-2,00	-2,00
	час									

Таблица 6 – Результаты сравнения прогнозной величины от фактической

Период прогнозирования 04.01.2016 середина праздничной недели									
Часы	X-4	X-2'	X-2	X-1	X-4	отклонения от факта, %			
						X-4	X-2'	X-4	X-4
1	2519	2519	2519	2519	2518	-0,07	-0,07	-0,07	-0,07
2	2466	2466	2466	2466	2506	1,60	1,60	1,60	1,60
3	2475	2475	2475	2475	2470	-0,19	-0,19	-0,19	-0,19
4	2486	2486	2486	2486	2508	0,88	0,88	0,88	0,88
5	2527	2527	2527	2527	2553	1,01	1,01	1,01	1,01
6	2562	2562	2562	2562	2609	1,84	1,84	1,84	1,84
7	2637	2637	2637	2637	2721	3,18	3,18	3,18	3,18
8	2702	2702	2702	2702	2820	4,37	4,37	4,37	4,37
9	2768	2768	2768	2768	2903	4,87	4,87	4,87	4,87
10	2805	2805	2805	2805	2948	5,07	5,07	5,07	5,07
11	2784	2784	2784	2784	2962	6,40	6,40	6,40	6,40
12	2788	2788	2788	2788	2971	6,57	6,57	6,57	6,57
13	2803	2803	2803	2803	2938	4,81	4,81	4,81	4,81
14	2787	2787	2787	2787	2956	6,06	6,06	6,06	6,06
15	2825	2825	2825	2825	2967	5,01	5,01	5,01	5,01
16	2975	2975	2975	2975	3059	2,81	2,81	2,81	2,81
17	3046	3046	3046	3046	3153	3,53	3,53	3,53	3,53
18	3016	3016	3016	3016	3113	3,21	3,21	3,21	3,21
19	2966	2966	2966	2966	3084	4,01	4,01	4,01	4,01
20	2908	2908	2908	2908	3046	4,76	4,76	4,76	4,76
21	2862	2862	2862	2862	2967	3,66	3,66	3,66	3,66
22	2764	2764	2764	2764	2832	2,45	2,45	2,45	2,45
23	2648	2648	2648	2648	2719	2,70	2,70	2,70	2,70
24	2592	2592	2592	2592	2650	2,25	2,25	2,25	2,25
сумма	65710	65710	65710	65710	67970				

max	МВт	3046	3046	3046	3046	3153	3,53	3,53	3,53	3,53
	час									

Таблица 7 – Результаты сравнения прогнозной величины от фактической

Период прогнозирования 16.04.2016 – окончание отопительного сезона										
Часы	X-4	X-2'	X-2	X-1	факт	отклонения от факта, %				
						X-4	X-2'	X-2	X-1	
1	2161	2112	2112	2112	2036	-5,77	-3,60	-3,60	-3,60	
2	2111	2071	2071	2071	2040	-3,35	-1,50	-1,50	-1,50	
3	2123	2053	2053	2053	2033	-4,26	-0,97	-0,97	-0,97	
4	2120	2060	2060	2060	2024	-4,54	-1,75	-1,75	-1,75	
5	2196	2086	2086	2086	1993	-9,26	-4,46	-4,46	-4,46	
6	2305	2157	2157	2157	2060	-10,61	-4,50	-4,50	-4,50	
7	2428	2265	2265	2265	2200	-9,38	-2,87	-2,87	-2,87	
8	2520	2353	2353	2353	2264	-10,14	-3,78	-3,78	-3,78	
9	2550	2389	2389	2389	2285	-10,39	-4,35	-4,35	-4,35	
10	2511	2383	2383	2383	2278	-9,29	-4,41	-4,41	-4,41	
11	2485	2374	2374	2374	2255	-9,25	-5,01	-5,01	-5,01	
12	2480	2369	2369	2369	2251	-9,22	-4,98	-4,98	-4,98	
13	2497	2355	2355	2355	2241	-10,24	-4,84	-4,84	-4,84	
14	2407	2311	2311	2311	2221	-7,71	-3,89	-3,89	-3,89	
15	2385	2296	2296	2296	2239	-6,13	-2,48	-2,48	-2,48	
16	2340	2276	2276	2276	2239	-4,31	-1,63	-1,63	-1,63	
17	2350	2291	2291	2291	2187	-6,95	-4,54	-4,54	-4,54	
18	2367	2303	2303	2303	2207	-6,76	-4,17	-4,17	-4,17	
19	2541	2440	2440	2440	2276	-10,45	-6,72	-6,72	-6,72	
20	2540	2445	2445	2445	2384	-6,15	-2,49	-2,49	-2,49	
21	2439	2351	2351	2351	2339	-4,12	-0,51	-0,51	-0,51	
22	2319	2235	2235	2235	2196	-5,28	-1,74	-1,74	-1,74	
23	2211	2148	2148	2148	2111	-4,51	-1,72	-1,72	-1,72	
24	2115	2077	2077	2077	2029	-4,04	-2,31	-2,31	-2,31	
сумма	56500	54200	54200	54200	52388					
max	МВт	2550	2445	2445	2445	2384	-6,51	-2,49	-2,49	-2,49
	час									

Таблица 8 – Результаты сравнения прогнозной величины от фактической

Период прогнозирования 01.06.2016 – начало периода ПЭВТ										
Часы	X-4	X-2'	X-2	X-1	факт	отклонения от факта, %				
						X-4	X-2'	X-2	X-1	
1	2051	2088	2088	2108	2186	6,59	4,72	4,72	3,74	
2	2026	2045	2045	2063	2158	6,56	5,53	5,53	4,62	
3	2002	2037	2037	2047	2067	3,23	1,45	1,45	0,96	
4	2011	2053	2053	2080	2077	3,25	1,13	1,13	-0,15	
5	2120	2165	2165	2169	2199	3,70	1,53	1,53	1,35	

6	2322	2328	2328	2334	2332	0,43	0,19	0,19	-0,08
---	------	------	------	------	------	------	------	------	-------

Продолжение таблицы 8

7	2511	2509	2509	2532	2545	1,37	1,42	1,42	0,50	
8	2625	2625	2625	2655	2736	4,23	4,23	4,23	3,06	
9	2696	2685	2685	2700	2768	2,67	3,08	3,08	2,50	
10	2632	2635	2635	2659	2736	3,95	3,87	3,87	2,91	
11	2635	2641	2641	2662	2773	5,24	5,01	5,01	4,17	
12	2689	2679	2679	2700	2804	4,29	4,68	4,68	3,86	
13	2734	2708	2708	2720	2817	3,02	4,04	4,04	3,58	
14	2641	2643	2643	2676	2799	5,98	5,90	5,90	4,60	
15	2602	2593	2593	2621	2738	5,22	5,58	5,58	4,45	
16	2558	2561	2561	2600	2736	6,95	6,82	6,82	5,23	
17	2539	2547	2547	2563	2667	5,06	4,73	4,73	4,07	
18	2486	2510	2510	2544	2653	6,73	5,69	5,69	4,30	
19	2471	2481	2481	2512	2598	5,15	4,72	4,72	3,45	
20	2586	2597	2597	2591	2631	1,75	1,34	1,34	1,57	
21	2612	2614	2614	2609	2717	4,02	3,97	3,97	4,15	
22	2419	2433	2433	2444	2545	5,23	4,60	4,60	4,15	
23	2262	2254	2254	2305	2398	6,03	6,41	6,41	4,06	
24	2133	2135	2135	2189	2271	6,47	6,39	6,39	3,75	
сумма	58364	58566	58566	59082	60953					
max	МВт	2734	2708	2708	2720	2817	3,02	4,04	4,04	3,58
	час									

Таблица 9 – Результаты сравнения прогнозной величины от фактической

Период прогнозирования 30.08.2016 – окончание периода ПЭВТ									
Часы	X-4	X-2'	X-2	X-1	факт	отклонения от факта, %			
						X-4	X-2'	X-2	X-1
1	2107	2111	2111	2087	2076	-1,51	-1,68	-1,68	-0,56
2	2068	2094	2094	2046	2038	-1,44	-2,65	-2,65	-0,38
3	2051	2074	2074	2025	2039	-0,59	-1,69	-1,69	0,71
4	2066	2082	2082	2050	2065	-0,07	-0,85	-0,85	0,69
5	2129	2152	2152	2115	2130	0,05	-1,02	-1,02	0,73
6	2271	2289	2289	2248	2248	-1,00	-1,77	-1,77	0,00
7	2465	2484	2484	2460	2417	-1,92	-2,68	-2,68	-1,72
8	2624	2636	2636	2605	2521	-3,94	-4,37	-4,37	-3,25
9	2707	2683	2683	2679	2567	-5,15	-4,32	-4,32	-4,16
10	2682	2648	2648	2643	2545	-5,10	-3,89	-3,89	-3,71
11	2689	2652	2652	2618	2563	-4,72	-3,37	-3,37	-2,13
12	2704	2663	2663	2628	2549	-5,75	-4,32	-4,32	-3,04
13	2707	2671	2671	2623	2574	-4,93	-3,63	-3,63	-1,87
14	2693	2635	2635	2610	2557	-5,07	-2,98	-2,98	-2,05

15	2672	2618	2618	2594	2553	-4,45	-2,50	-2,50	-1,60
16	2635	2584	2584	2575	2491	-5,49	-3,62	-3,62	-3,29
17	2594	2583	2583	2557	2504	-3,45	-3,05	-3,05	-2,08

Продолжение таблицы 9

18	2555	2572	2572	2505	2507	-1,88	-2,51	-2,51	0,09	
19	2544	2579	2579	2484	2537	-0,30	-1,66	-1,66	2,13	
20	2634	2662	2662	2605	2618	-0,63	-1,66	-1,66	0,48	
21	2576	2572	2572	2563	2483	-3,61	-3,45	-3,45	-3,12	
22	2411	2386	2386	2411	2278	-5,52	-4,53	-4,53	-5,52	
23	2252	2225	2225	2248	2183	-3,08	-1,89	-1,89	-2,87	
24	2162	2144	2144	2156	2108	-2,49	-1,70	-1,70	-2,21	
сумма	59000	58800	58800	58136	57149					
max	МВт	2707	2683	2683	2679	2618	-3,31	-2,44	-2,44	-2,27
	час	0	0	0	0	0				

Таблица 10 – Результаты сравнения прогнозной величины от фактической

Период прогнозирования 08.03.2016 – международный женский день									
Часы	X-4	X-2'	X-2	X-1	факт	отклонения от факта, %			
						X-4	X-2'	X-2	X-1
1	2426	2409	2409	2440	2357	-2,84	-2,15	-2,15	-3,39
2	2400	2396	2396	2416	2364	-1,52	-1,36	-1,36	-2,19
3	2397	2386	2386	2409	2355	-1,77	-1,31	-1,31	-2,24
4	2395	2403	2403	2434	2337	-2,44	-2,77	-2,77	-3,98
5	2413	2444	2444	2471	2370	-1,77	-3,04	-3,04	-4,09
6	2441	2486	2486	2511	2422	-0,76	-2,55	-2,55	-3,54
7	2484	2533	2533	2564	2461	-0,95	-2,87	-2,87	-4,05
8	2606	2639	2639	2645	2580	-1,02	-2,27	-2,27	-2,47
9	2686	2694	2694	2704	2608	-2,92	-3,22	-3,22	-3,55
10	2732	2714	2714	2727	2610	-4,45	-3,82	-3,82	-4,28
11	2729	2697	2697	2704	2598	-4,81	-3,68	-3,68	-3,91
12	2707	2698	2698	2679	2566	-5,21	-4,90	-4,90	-4,21
13	2694	2688	2688	2673	2563	-4,86	-4,64	-4,64	-4,10
14	2680	2668	2668	2668	2541	-5,17	-4,76	-4,76	-4,75
15	2686	2691	2691	2703	2547	-5,18	-5,37	-5,37	-5,76
16	2717	2727	2727	2739	2557	-5,88	-6,24	-6,24	-6,63
17	2779	2770	2770	2790	2590	-6,80	-6,50	-6,50	-7,16
18	2884	2863	2863	2880	2755	-4,46	-3,75	-3,75	-4,32
19	2854	2824	2824	2820	2770	-2,95	-1,92	-1,92	-1,78
20	2822	2797	2797	2826	2730	-3,26	-2,41	-2,41	-3,39
21	2737	2707	2707	2697	2672	-2,37	-1,30	-1,30	-0,94
22	2631	2598	2598	2585	2542	-3,40	-2,16	-2,16	-1,69
23	2562	2509	2509	2542	2444	-4,61	-2,58	-2,58	-3,87
24	2496	2457	2457	2492	2404	-3,69	-2,16	-2,16	-3,55

сумма		62958	62800	62800	63118	60741				
max	МВт	2884	2863	2863	2880	2770	-3,96	-3,25	-3,25	-3,82
	час									

Полученные данные свидетельствуют о том, что введение возможности учета метеофакторов в модель прогнозирования электропотребления повышает эффективность работы ИНС. Таким образом, созданная статистическо-динамическая модель потребления Самарской энергосистемы на базе ИНС удовлетворяющей требованиям к качеству краткосрочного прогнозирования потребления в энергосистемах. Учитывая, что в основной массе автоматизированные программные комплексы дают ошибку в 5-6%, ошибка прогнозирования в 1,82% - это очень хороший результат.

Вывод по главе 3

В данной главе проведено исследование возможности введения в модель прогнозирования на базе ИНС сети возможности учета факторов влияющих на качество прогнозирования. Проведённый сравнительный анализ результатов прогнозирования с использованием данной модели и модели без учета влияния факторов показал, что выбранный подход по выбранной архитектуре, алгоритму обучения и учету метеофакторов, удовлетворяет необходимым требованиям, которые были заданы на начальном этапе создания статистическо-динамической модели прогнозирования на базе ИНС. Можно сделать вывод, что архитектура ИНС построена верно, выбранный алгоритм обучения с возможностью учета метеофакторов делают модель эффективной.

Заключение

В данной работе рассмотрены технические и рыночные механизмы определяющие требования к краткосрочному и оперативному прогнозированию электропотребления в энергосистемах. В частности рассмотрены вопросы влияния качества прогнозов на деловые процессы на оптовом рынке электроэнергии и мощности.

Проведен анализ существующей методики прогнозирования потребления в энергосистемах, а так же методика учета влияния температурных факторов на степень влияния графика потребления мощности и электрической энергии в энергосистемах.

В качестве альтернативы существующих методик была рассмотрена альтернативная методика прогнозирования на основе использования искусственных нейронных сетей (ИНС).

Решены задачи реализации ИНС на программном уровне. Для эти целей был выбран модуль программы MATLAB с пакетом инструментов Neural Network Toolbox исходя из удобства и доступности, и самое главное по наличию инструментов неограничивающих в творческих и инженерных подходах и идеях, для формирования статистическо-динамической модели прогнозирования потребления Самарской области на базе ИНС.

Была проведена огромная аналитическая и экспериментальная работа по подбору архитектуры ИНС и алгоритма обучения, на основании полученных результатов для прогнозирования была выбрана нейронная сеть с нелинейной авторегрессией и обучением по принципу регуляризации Байеса.

После проведенной работы по адаптации сети для создания возможности учета этих метеофакторов, ошибка прогнозирования составила 1,82% отклонений в час максимального потребления мощности. Проведённый сравнительный анализ результатов прогнозирования с использованием данной модели и модели без учета влияния факторов показал, что выбранный подход

по выбранной архитектуре, алгоритму обучения и учету метеофакторов, удовлетворяют необходимым требованиям, которые были заданы на начальном этапе создания статистическо-динамической модели прогнозирования на базе ИНС. Можно сделать вывод, что архитектура ИНС построена верно, выбранный алгоритм обучения с возможностью учета метеофакторов делают модель эффективной.

Список использованных источников

1. **Постановления Правительства Российской Федерации.** Функционирование розничных рынков электрической энергии, полном и (или) частичном ограничении режима потребления электрической энергии от 04.05.2012 № 442 // Российская газета.
2. **Постановления Правительства Российской Федерации.** Утверждение Правил оптового рынка электрической энергии и мощности и о внесении изменений в некоторые акты Правительства Российской Федерации по вопросам организации функционирования оптового рынка электрической энергии и мощности от 04.12.2010 № 1172 // Парламентская газета.
3. **Российская Федерация. Законы.** Об энергосбережении и о повышении энергетической эффективности и о внесении изменений в отдельные законодательные акты Российской Федерации [Текст] : федер. закон : [принят Гос. Думой 11 ноября 2009 г. : одобр. Советом Федерации 18 ноября 2009 г.]. – М. : - (Актуальный закон).
4. **ГОСТ 32144-2013.** Электрическая энергия. Совместимость технических средств электромагнитная. Нормы качества электрической энергии в системах электроснабжения общего назначения [Текст]. – Введ. 2013-03-25. – М.: Стандартинформ, 2014.
5. Правила устройств электроустановок [Текст] : утв. М-вом энергетики Рос. Федерации 08.07.02 : введ. в действие с 01.01.2003 – 7-е изд. – М.: ЭНАС, 2005.
6. **Стандарт организации АО «СО ЕЭС» СТО 59012820.27.010.007-2016.** Резервы активной мощности Единой энергетической системы России. Определение объемов резервов активной мощности при краткосрочном планировании [Текст]. – Введ. 2016-03-25. – М.: Стандартинформ, 2014.

7. Методика прогнозирования графиков электропотребления для технологий краткосрочного планирования назначения [Текст]. – Введ. 2007-12-14. – М.: Стандартиформ, 2007.
8. Жуков Д.М. Повышение эффективности функционирования систем электроснабжения промышленных предприятий путем оптимизации прогнозирования потребления электроэнергии [Текст] дис. ... канд. техн. наук: 05.09.03 / Жуков, Денис Михайлович. – Липецк, 2007, 151 с. РГБ ОД, 61 07-5/4912
9. Сакиев А.В. Разработка системы планирования производственных показателей региональной энергосистемы [Текст] дис. ... канд. техн. наук: 05.13.01 / Сакиев Альберт Валерьевич. – Владикавказ, 2005, 163 с. РГБ ОД, 61:06-5/678
10. Карпова, Т.С. Базы данных: модели, разработка, реализация [Текст] / Т.С. Карпова ; - СПб.: Питер, 2001. С. 286-289.
11. Боровиков, В.П. Нейронные сети. Statistica Neural Networks. Методология и технологии современного анализа данных [Текст] / В.П. Боровиков. - 2 изд. - М.: Горячая линия - Телеком, 2008. С. 114.
12. Хайкин, С. Нейронные сети: полный курс [Текст] / С. Хайкин - 2 изд. - М.: Вильямс, 2006. С. 89-102.
13. Галушкин, А.И. Нейронные сети: основы теории [Текст] / А.И. Галушкин - М.: Горячая Линия - Телеком, 2010. С. 56.
14. Аксенов, С.В. Организация и использование нейронных сетей (методы и технологии) [Текст] / С.В. Аксенов, В.Б. Новосельцев - Томск: НТЛ, 2006. С.15-19.
15. Бодянский, Е.В. Искусственные нейронные сети: архитектуры, обучение, применение [Текст] / Е.В. Бодянский, О.Г. Руденко - Харьков: Телетех, 2004. С. 304.

16. Круглов, В.В. Нечеткая логика и искусственные нейронные сети [Текст] / В.В. Круглов, М.И. Дли, Р.Ю. Голунов - М.: Издательство Физико-математической литературы, 2001.
17. Толкачев, С.Ф. Нейронное программирование диалоговых систем [Текст] / С.Ф. Толкачев - СПб.: Корона-Век, 2016.
18. Hagan M. T. Neural Network Design (2nd Edition) [Текст] / Martin T. Hagan, Howard B. Demuth, Mark H. Beale, Orlando De Jesús. - Martin Hagan, 2014. – 800 с. ISBN 0971732116.
19. 6. Heaton J, Introduction to the Math of Neural Networks [Текст] / Jeff Heaton. - Heaton Research, Inc., 2013. – 119 с.
20. 7. Shankar R. Neural Networks [Текст] / Raghava Shankar. - Independently published, 2016. – 142 с. ISBN 1519093136
21. 8. Goldberg Y. Neural Network Methods in Natural Language Processing (Synthesis Lectures on Human Language Technologies) [Текст] / Yoav Goldberg, Graeme Hirst. - Morgan & Claypool Publishers, 2017. – 310 с. ISBN 1627052984
- Дерябин, В.В. Нейросетевые алгоритмы в задаче счисления пути судна [Текст] / В.В. Дерябин // Наука и транспорт - 2012. - №2. - С. 74-75.
22. Рузанов, Р.В. Прогнозирование электропотребления энергосбытовой компании с использованием искусственных нейронных сетей [Текст] / Р.В. Рузанов // Энергетика. Проблемы и перспективы развития - Тамбов: ФГБОУ ВПО «ТГТУ» - 2015.
23. Кретов, Д.А. Анализ эффективности использования искусственной нейронной сети для прогнозирования электропотребления энергосбытовой компании [Текст] / Д.А. Кретов, Р.В. Рузанов // Молодые ученые - ускорению научно-технического прогресса в XXI веке - Ижевск: ИННОВА - 2015.
24. Кретов, Д.А. Краткосрочное прогнозирование электропотребления энергосбытовой компании с использованием искусственной нейронной сети [Текст] / Д.А. Кретов, Р.В. Рузанов // Электроэнергетика глазами молодежи -

Иваново: ФГБОУ ВПО «Ивановский государственный энергетический университет им. В.И. Ленина» - 2015.

25. Макаклюев Б.И. Методы и средства анализа и планирования электропотребления энергообъединений и энергосистем [Текст] дис. ... док. тех. наук : 05.14.02 / Макаклюев Борис Иванович. - Москва, 2005, 295 с. РГБ ОД, 71:06-5/173

26. Кретов, Д.А. Прогнозирование электропотребления энергосбытовой компании с использованием искусственной нейронной сети [Электронный ресурс] / Д.А. Кретов, Р.В. Рузанов // Инженерный вестник Дона. – 2015. - №2.

27. Назаров В.Н. Моделирование принятия решений в автоматизированной системе управления региональным энергопотреблением на примере Воронежской энергосистемы [Текст] дис. ... канд. техн. наук: 05.13.18 / Назаров Виктор Николаевич. – Воронеж, 2002, 158 с. РГБ ОД, 61 03-5/3450-5

28.

29. Галушка, В.В. Формирование обучающей выборки при использовании искусственных нейронных сетей в задачах поиска ошибок баз данных [Электронный ресурс] / В.В. Галушка, В.А. Фатхи // Инженерный вестник Дона. – 2013. - №2.

30. Пучков Е.В. Сравнительный анализ алгоритмов обучения искусственной нейронной сети [Электронный ресурс] / Е.В. Пучков // Инженерный вестник Дона. – 2013. - №4.

31. Администратор торговой системы. – (<https://www.atsenergo.ru/results/rsv/indexes.html>).

32. Ассоциация НП Совет Рынка. - (<http://www.npsr.ru/regulation/joining/reglaments/index.html>).

33. StatSoft. – (http://www.statsoft.ru/products/STATISTICA_Neural_Networks.html).

34. Mathworks. – (<http://www.mathworks.com/products/neural-network.html>).

35. Центр финансовых расчетов. —
(http://cfrenergo.ru/calculations_OREM/calculations.html).

36. Министерство энергетики и жилищно-коммунального хозяйства Самарской области. —
(http://www.minenergo.samregion.ru/norm_base/prikaz_regulirovanae2013/23700.html)