

# ПРОГНОЗИРОВАНИЕ РАБОТОСПОСОБНОСТИ СУДОВОЙ ЭЛЕКТРОЭНЕРГЕТИЧЕСКОЙ СИСТЕМЫ НА БАЗЕ ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ

Гвоздева И. М., Луковцев В. С., Терельник С. А.

## 1. Введение

Анализ причин аварий судовых электроэнергетических систем (СЭЭС) [1] показывает, что значительная их часть произошла из-за несвоевременного определения предаварийного состояния, а также неверных и неэффективных действий экипажей морских судов во время самой аварии. Поэтому одной из задач при создании эффективной системы управления является разработка и совершенствование структур программных и аппаратных средств, способствующих накоплению и анализу информации о состоянии СЭЭС с целью предотвращения аварий.

## 2. Объект исследования и его технический аудит

Объект исследования – процесс прогнозирования работоспособности СЭЭС. Для снижения вероятности наступления аварии СЭЭС необходимо, чтобы системы автоматизации могли решать задачи не только традиционного мониторинга, но и задачи прогнозирования для возможности успешного управления в предаварийных, аварийных и послеаварийных режимах работы.

Работа СЭЭС контролируется по режимным параметрам (напряжение, мощность, частота и т. д.) посредством системы мониторингового контроля.

Так как процессы, протекающие в СЭЭС, можно контролировать по совокупности изменяющихся по определенным законам параметров:

$$x_1, x_2, \dots, x_n,$$

то внешние информационные характеристики процесса или режима могут быть представлены в виде множества векторов или матрицы, которая однозначно отображает состояние процесса в фиксированные моменты времени:

$$X^* = \begin{pmatrix} x_1(t_1) & x_1(t_2) & \dots & x_1(t_k) \\ x_2(t_1) & x_2(t_2) & \dots & x_2(t_k) \\ \dots & \dots & \dots & \dots \\ x_n(t_1) & x_n(t_2) & \dots & x_n(t_k) \end{pmatrix}. \quad (1)$$

Вектор параметров описывает некоторую траекторию, которая позволяет исследовать поведение объекта и в перспективе определять состояние и режим работы СЭЭС.

Прогнозирование работоспособности СЭЭС заключается в оценке ее параметров по данным измерений, поступающих от объектов контроля в оперативные информационно-вычислительные комплексы на базе ЭВМ, основанных на математических методах обработки данных, которые в большинстве случаев, сводятся к решению линейных детерминированных многопараметрических задач, в основе которых лежат методы прогнозирования. Широкое использование, при оперативном управлении, данных о состоянии режима работы объекта предъявляет высокие требования к быстродействию информационно-вычислительных комплексов. Темп решения задач реального времени очень высок, так как объем информации, подлежащий обработке, достигает десятки тысяч и более аналоговых измерений при цикле поступления 1–10 секунд. В то же время уровень методических и алгоритмических разработок достиг состояния, когда основным ограничивающим фактором на пути оптимизации процесса прогнозирования работоспособности СЭЭС является производительность ЭВМ. В связи с этим возникает необходимость разработки средств автоматизации, которые позволят расширить номенклатуру выполняемых ими функций.

### **3. Цель и задачи исследования**

Целью данной работы является разработка системы прогнозирования состояний СЭЭС на базе искусственной нейронной сети (ИНС).

Для достижения поставленной цели были поставлены следующие задачи:

1. Нормализация данных, характеризующих состояние СЭЭС.
2. Выбор топологии и обучение ИНС.

### **4. Исследование существующих решений проблемы**

Методам прогнозирования показателей, характеризующих состояние технических объектов, всегда уделялось большое внимание. В большинстве случаев, анализ опирается на ряд статистических методов [2]: корреляционные, регрессионные и факторные; эконометрические и эвристические; временной и пространственной экстраполяции; моделирования процессов развития.

По оценкам исследователей [2–5] число различных методов и приемов прогнозирования превысило 400. Однако число базовых процедур, повторяющихся в различных вариациях в других методах, не превышает десятка. Специфика исходной информации и анализируемого объекта требует выбора адекватного метода при разработке систем прогнозирования. Так как цель настоящей работы состоит в разработке системы прогнозирования работоспособности СЭЭС, то анализ методов прогнозирования будет касаться только тех методов, которые целесообразно применять в технических системах.

Так, в работе [6] рассмотрен метод эвристического прогнозирования. В широком смысле, эвристическое прогнозирование заключается в интуитивном выборе из бесчисленного множества обстоятельств важнейших и решающих факторов. Основная процедура прогноза заключается в сравнении всех величин и вариантов, с помощью которого устраняется все маловажное и несущественное. Эффективность методов эвристического прогнозирования повышается не за счет их внутренней структуры, а за счет внешнего оформления:

подбора соответствующих по квалификации и количеству экспертов, а также совершенствования алгоритмов обработки результатов опроса. В соответствии с этим, были разработаны методы индивидуальных экспертных оценок, как, например, интервью и аналитические оценки. Основные методы коллективных экспертных оценок включают в свой состав методы комиссий, коллективной генерации идей, матричный метод и другие [2].

Однако эвристические методы субъективны и пригодны только тогда, когда существуют эксперты, хорошо знакомые с прогнозируемой ситуацией. Кроме того, при прогнозировании характеристик сложных технических объектов, таких как СЭС, методы эвристического прогнозирования становятся весьма сложными и трудоемкими.

Данное обстоятельство потребовало разработки математических методов прогнозирования. Основные достоинства таких методов состоят в объективности получаемой информации и в возможности автоматизации процесса прогнозирования с использованием ЭВМ.

В зависимости от используемого математического аппарата и целевой направленности, математические методы временной экстраполяции можно условно разделить на три группы:

- 1) методы аналитического прогнозирования;
- 2) методы вероятностного прогнозирования;
- 3) методы статистической классификации.

В тех случаях, когда контролируемый процесс «информативен» во времени [7], задачу прогнозирования можно решить различными методами, называемыми методами аналитического прогнозирования и отличающимися применяемым математическим аппаратом. Существует ряд методов аналитического прогнозирования, учитывающих производные изменений функции состояния. К числу таких методов относят операторный метод [8], метод суммирования производных [9] и другие методы. Модели прогнозирования, учитывающие производные функционала состояния, обладают неопределенностью начальных условий, поэтому при случайных помехах начальная неопределенность возрастает, что затрудняет определение параметров модели. Как следствие, ухудшается точность прогнозирования. Наиболее распространенным прогнозирующим аналитическим методом является метод, основанный на применении базисных функций, который подходит для описания монотонного и постепенного изменения параметров [10, 11]. К недостаткам данного метода можно отнести сложность и трудоемкость вычислений, связанных с необходимостью выбора и вычисления для каждого параметра прогнозирующего аналитического выражения.

К общим недостаткам методов аналитического прогнозирования следует отнести большой объем вычислительных процедур при определении прогнозных значений параметров, а также неточность результатов прогнозирования при неправильно выбранной модели. Кроме того, приходится учитывать неточности исходных данных, полученных в период наблюдения.

Необходимость вероятностного прогнозирования определяется сильным влиянием внешних и внутренних факторов, имеющих случайный характер. К ме-

тодам вероятностного прогнозирования относится, например, метод статистического градиента [12]. Метод, использующий Байесов критерий, позволяет определить плотность распределения вектора градиента функции состояния [13]. Для определения наиболее вероятного направления градиента в этом случае строится распределение приращений по каждой координате вектора функции состояния. Метод гипотез и фильтрации состоит в том, что вводится гипотеза о том или ином поведении функции, а затем все результаты контроля и прогнозирования, не удовлетворяющие принятой гипотезе, отфильтровываются. Недостатком систем прогнозирования с применением данных методов является низкая оперативность из-за инерционности в получении результатов прогноза.

В рамках следующего метода рассматривается функция распределения параметров с преобладанием случайных составляющих [14]. Прогнозирование изменений этой функции заключается в вычислении статистических характеристик и построении интегральных функций распределений различных последовательностей временных рядов. Существенным недостатком метода является необходимость длительного наблюдения при индивидуальном прогнозировании для получения представительных выборок.

Для получения непрерывного прогноза используются оптимальные фильтры: фильтр Винера-Хопфа [15] для прогнозирования стационарных процессов и фильтр Калмана [16] для нестационарных процессов. Принципиальными трудностями применения этих фильтров является громоздкость вычислительных процедур и необходимость наличия представительных статистических данных. Метод статистической регрессии позволяет предсказать одну или несколько величин на основе информации о параметрах объекта. Задача заключается в определении такой функции модели, зная которую можно с некоторой достоверностью судить об изменении прогнозируемой величины в зависимости от аргументов [17]. Данный метод объективен, но требует соблюдения ряда условий для успешного применения. Прежде всего, необходим достаточно большой объем статистических данных, полученных на участке наблюдения. Кроме того, необходимо знать вид детерминированной основы процесса или функции, описывающей процесс изменения параметров. Самым большим недостатком метода является невозможность предсказания качественного изменения характера динамики технического состояния объекта, т. е. скачка.

Необходимость наличия представительного объема статистических данных о процессах изменения параметров и невозможность прогноза резких изменений на участке прогнозирования можно отнести к общим недостаткам большинства систем прогнозирования с применением вероятностных методов.

Широкое распространение получили системы прогнозирования, основанные на методах статистической классификации. В работе [18] применяют экспоненциальное сглаживание – метод Бокса-Дженкинса. Модель Бокса-Дженкинса [17] основана на обработке авторегрессионных рядов, в которых не делается никаких априорных допущений относительно дисконтирующих коэффициентов. При этом используется переход к разностям ряда и допускается коррелированность остатков с представлением их

скользящим средним [11]. Алгоритм прогнозирования представляет собой фильтр второго порядка.

В работе [2] рассмотрен метод, в основе которого лежит спектральный анализ. Спектром временной зависимости функции называется совокупность ее гармонических составляющих, образующих ряд Фурье. Спектральный анализ обеспечивает возможность вычисления амплитуды и фазы любой гармоники (или спектральной плотности на любой частоте). На основе разложения временного ряда на составляющие разработан метод спектральной декомпозиции для учета различных регулярных колебаний. Если из фактических значений выделить регулярные изменения, остаточный ряд будет представлять флуктуации значений параметров относительно систематических изменений, обусловленных влиянием локальных факторов.

Для моделирования различных процессов применяется метод Монте-Карло, основанный на использовании случайных чисел [19]. Обобщенный алгоритм реализации метода Монте-Карло обеспечивает прогнозирование работы объекта и вычисление статистических характеристик его функциональных параметров. Оценка точности полученных прогнозных значений производится двумя способами: априорным и апостериорным [20].

Существенным недостатком всех систем прогнозирования, основанных на методе статистической классификации, можно считать обязательное наличие априорной информации, на основе которой и осуществляется установление временных экстраполяционных связей. По сути, необходима выборка данных по объекту одного типа с объектом, показатели которого необходимо прогнозировать.

В последнее время значительный интерес проявляется к методам, основанным на нелинейных моделях. Большая часть таких методов принадлежит к разряду технологий искусственного интеллекта [21]. Это, в первую очередь, искусственные нейронные сети и новейшие средства оптимизации, к числу которых относятся, например, генетические алгоритмы [22, 23], метод моделирования отжига [24] и другие [25–27].

## **5. Методы исследования**

В качестве метода исследования выбран метод компьютерного моделирования, который сегодня является одним из основных методов исследования сложных систем и физических процессов.

## **6. Результаты исследования**

### **6.1. Нормализация входных данных (нормирование параметров)**

В связи с тем, что режим технического объекта характеризуются параметрами различной физической природы, которые имеют различную размерность, все параметры приводим к единой системе счисления, в качестве которой выбрана система безразмерного (нормированного) относительного счисления.

Если для каждого параметра  $x_n$ ,  $n=1, 2, \dots$ , имеется возможность выделить допустимое  $x_n^*$ , и оптимальное (номинальное)  $x_{\text{опт}}$  значения, то безразмерный параметр можно записать в виде [28]:

$$\hat{x}_n(t) = \frac{x_n(t) - x_n^*}{x_{\text{опт}} - x_n^*}, \quad (2)$$

где  $0 \leq x_n(t) \leq 1$  при  $x_n(t) = x_{\text{опт}}$   $\hat{x}_n(t) = 1$ , а при  $x_n(t) = x_n^*$ ,  $\hat{x}_n(t) = 0$ .

Нормируемый параметр  $x_n(t)$ , в виде безразмерной нормированной величины  $\hat{x}_n(t)$  при изменении параметра  $x_n$  от  $x_{\text{опт}}$  до  $x_n^*$  меняется во времени от 0 до 1, позволяя судить о степени запаса работоспособности режима объекта по данному параметру.

## 6.2. Задача классификации режимов СЭЭС

Режим работы объекта контролируют по отклонению рабочих параметров от установленной нормы, при повышении значения параметра выдается аварийный сигнал.

Возникает необходимость в прогнозировании, чтобы иметь возможность сделать предупредительное управление объектом с целью предупреждения перехода СЭЭС в предаварийный режим.

Анализ информации о режимах работы технического объекта состоит в классификации сигналов от датчиков и отнесение воспринимаемой совокупности параметров (3) к области характеризующей одно из технических состояний объекта «Исправно», «Предупреждение», «Отказ».

$$X = (x_1, x_2, \dots, x_n). \quad (3)$$

С этой целью пространство параметров разбивается по какому-либо критерию на  $n$ -областей (4).

$$X_1, X_2, \dots, X_i. \quad (4)$$

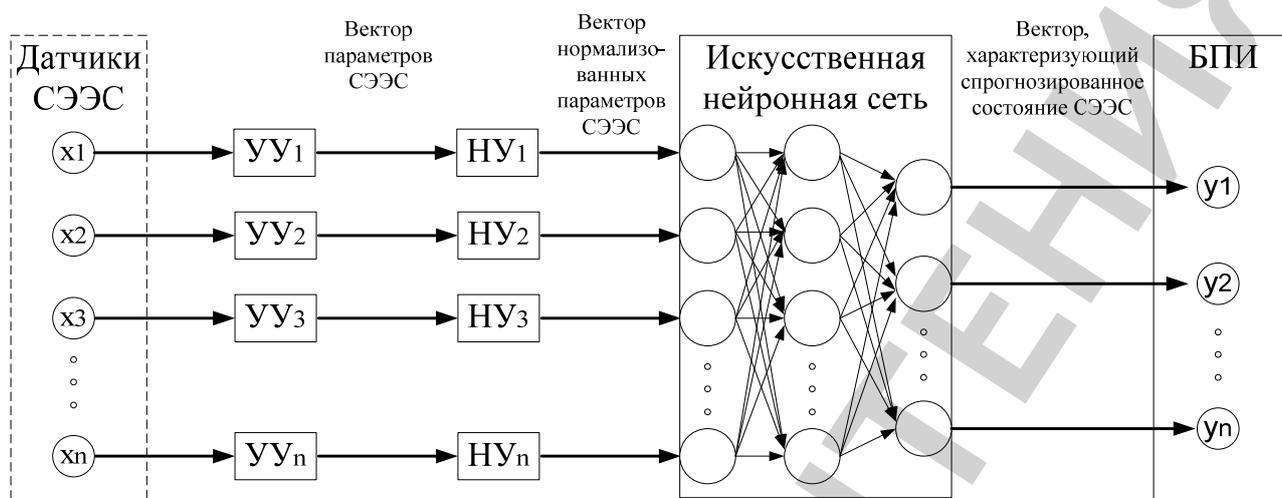
Вектор  $X_i$  в пространстве признаков (параметров) называется вектором реализации.

Таким образом, задача распознавания технических состояний формулируется как задача классификации образов.

## 6.3. Реализация системы прогнозирования на базе ИНС

Эффективность применения нейронных сетей заключается в возможности распараллеливания обработки информации и способности самообучаться, т. е. создавать обобщения. Эти свойства позволяют повысить быстродействие управления системы при идентификации режима СЭЭС и последующем его прогнозировании. На рис. 1 показана структурная схема реализации системы прогнозирования работоспособности СЭЭС, где УУ – устройства усиления, НУ – нормирующие устройства, приводящие физические параметры различной

природы к единой системе измерения (относительные единицы), БПИ – блок представления информации.



**Рис. 1.** Структура реализации системы прогнозирования работоспособности судовой электроэнергетической системы на базе искусственных нейронных сетей

Выбор топологии нейронной сети зависит от исходных данных и типа решаемой задачи. В настоящее время существует множество видов ИНС различающихся по структуре, а также по алгоритмам и методикам обучения [29, 30]. Но так как исходные данные, обработку которых производит ИНС, представляют собой временной ряд, состоящий из значений параметров СЭЭС, измерение которых проводится с определенным интервалом времени (доля секунды, секунда, минута и т. д.), в качестве базовой подойдет архитектура многослойного персептрона [31].

## 6.4. Обучение ИНС

Тип обучения определяется способом подстройки этих параметров. Блочная диаграмма процесса обучения ИНС изображена на рис. 2.

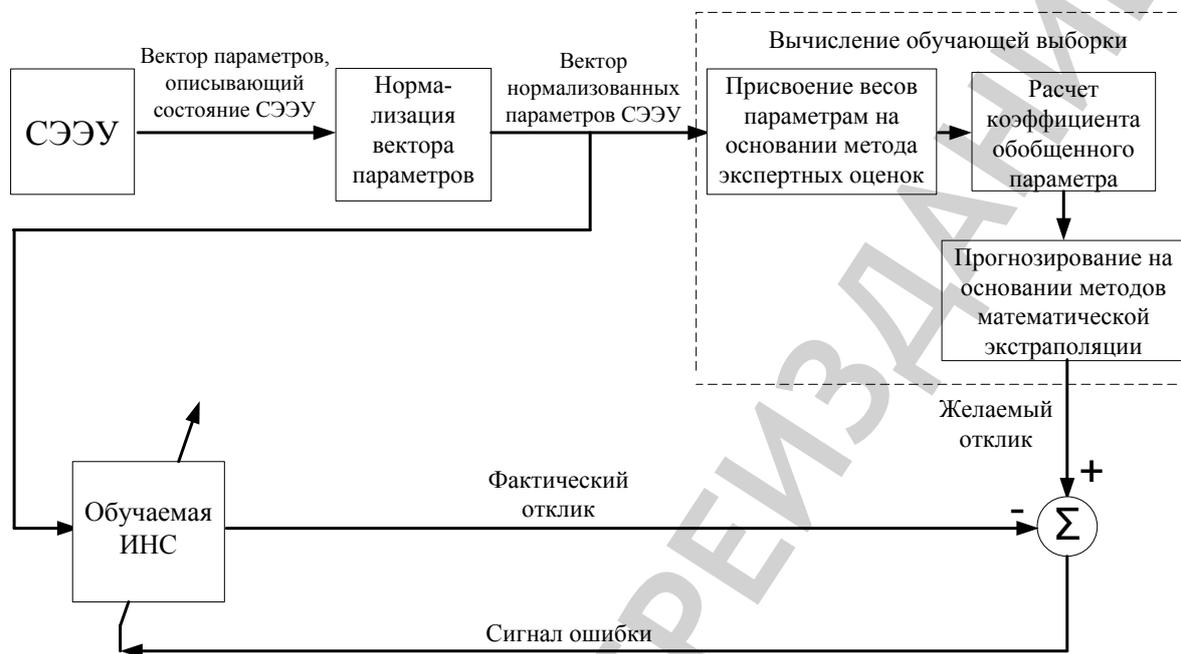


Рис. 2. Блок-диаграмма обучения искусственной нейронной сети

На рис. 2 показана блочная диаграмма, иллюстрирующая процесс обучения ИНС. Вектор параметров, описывающий состояние СЭЭС подается на блок нормализации величин параметров. Далее вектор нормализованных параметров подается на обучающий блок (блок вычисления обучающей выборки для ИНС). Так как количественно одинаковые значения этих величин не являются равнозначными по степени влияния на изменение режима объекта, их необходимо дифференцировать, т. е. учесть степени влияния каждого параметра на рабочий режим объекта. Это достигается путем введения положительных весовых коэффициентов  $\mu_i$  контролируемых параметров, величины которых характеризуют значимость соответствующих параметров. Веса могут быть получены методом экспертной оценки [32, 33]. Далее производится расчет коэффициента обобщенного параметра. Для определения обобщенного параметра  $Q_\Sigma$ , наиболее целесообразно воспользоваться формулой, разработанной в работе [32]:

$$Q_\Sigma = \frac{\left( \prod_{i=1}^n \hat{X}_i^{\mu_i} \right)^{\frac{1}{n^2}}}{\left[ \sum_{i=1}^n \left( \hat{X}_i^{\mu_i} \right)^2 \right]^{\frac{1}{2}}}, \quad (5)$$

где  $i$  – количество параметров;  $\hat{X}_i$  – нормированное значение параметра;  $\mu_i$  – вес каждого параметра.

Далее, при наличии нескольких последовательных замеров и спрогнозированных значений обобщенного параметра, сделанных через равные промежутки времени, с помощью их обработки можно выявить тенденции их изменения в будущем. То есть выполнить прогнозирование величины обобщенного параметра на следующий цикл, либо когда этот параметр достигнет аварийного значения.

Прогностический контроль параметров связан с измерением скорости его изменения и последующей экстраполяцией его значения с целью установления периода времени, через который может наступить аварийная ситуация (предельное значение величины контролируемого параметра).

Учитывая то, что процессы в СЭЭС относительно инерционны, можно выявить тенденцию к их изменению методом экстраполяции. Поскольку замеры и вычисления обобщенного параметра были сделаны в равные промежутки времени, то в качестве функции можно использовать не время, а номер замера.

Интерполяционная или экстраполяционная функция являются аналитической формой представления этой тенденции в предположении, что она остается неизменной на какой-то момент времени. Это позволяет утверждать, что для физического объекта можно осуществлять прогнозирование изменения его параметров, поскольку последний обладает инерционностью.

Известны различные методы отыскания таких функций. Наиболее простой метод заключается в подборе полинома, аппроксимирующего эту функцию и имеющего минимальные вариации (отклонения). Обычно используют полиномы 1-2-3-ей степени [34].

Полученные данные на основе расчетов, описанных выше, можно рассматривать как наличие знаний о рассматриваемом объекте (СЭЭС), представленных в виде пар входных-выходных векторов, то есть результаты расчетов используются в качестве обучающей выборки для ИНС. При этом отсутствует предварительная информация о СЭЭС. Теперь предположим, что прогнозирующему расчетному блоку и обучаемой ИНС подается обучающий вектор характеризующий состояние СЭЭС. На основании расчетов можно сформировать и передать обучаемой нейронной сети желаемый отклик, соответствующий данному входному вектору. Этот желаемый результат представляет собой оптимальные действия, которые должна выполнить нейронная сеть. Параметры сети корректируются с учетом обучающего вектора и сигнала ошибки – разность между желаемым сигналом (результатом расчетов) и текущим откликом нейронной сети. Сигнал ошибки можно представить в виде [29, 30]:

$$e_i = y_i - \tilde{y}_i, \quad (6)$$

где  $e_i$  – сигнал ошибки;  $y_i$  – желаемый отклик ИНС;  $\tilde{y}_i$  – фактический отклик ИНС.

Корректировка параметров выполняется пошагово, используя алгоритм обратного распространения ошибки [29, 30, 31], с целью имитации нейронной

сеть расчетов. Таким образом, в процессе обучения «знания», полученные в результате расчетов, передаются в сеть в максимально полном объеме.

### 6.5. Программная реализация и результаты исследования

Для программной реализации была выбрана программа NeuroPro [35].

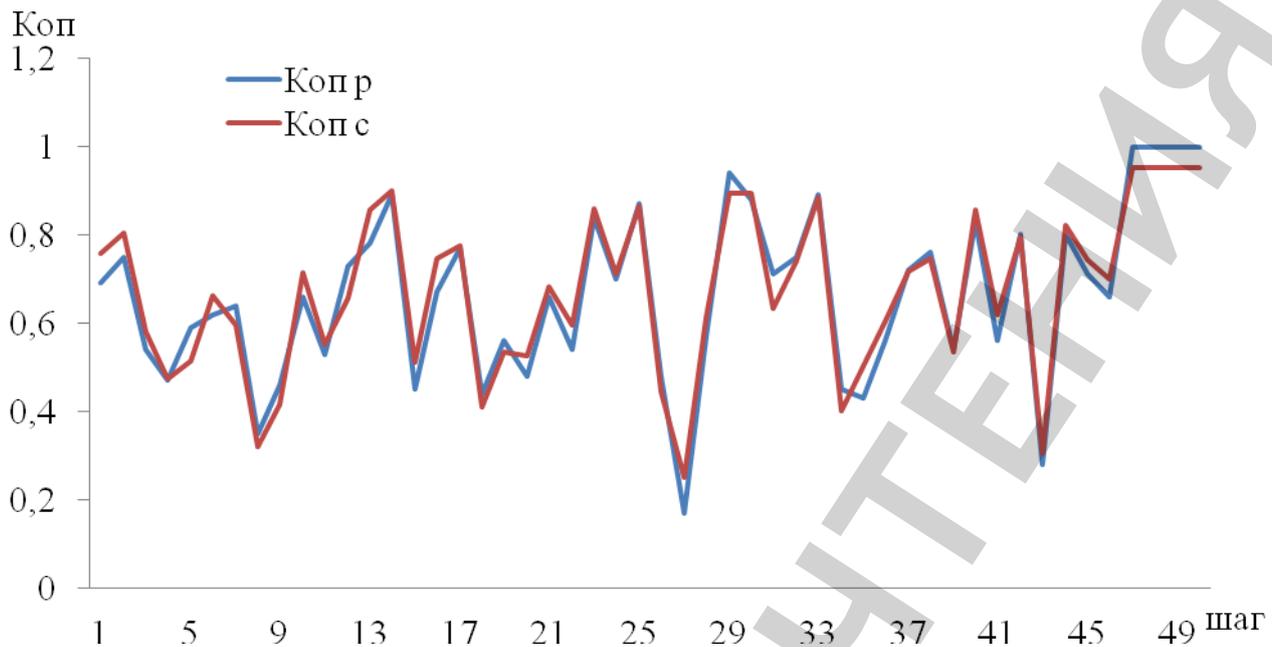
В качестве обучающего множества были взяты данные, полученные в результате расчетов коэффициента обобщенного параметра (табл. 1).

**Таблица 1**

Результаты расчетов и прогнозирования значений коэффициента обобщенного параметра

No	Расчетное значение $K_{оп}$	Спрогно- зирован- ное значе- ние $K_{оп}$	Ошибка сети	No	Расчетное значение $K_{оп}$	Спрогно- зирован- ное значе- ние $K_{оп}$	Ошибка сети
1	0,69	0,758191	-0,06819	26	0,48	0,444702	0,035298
2	0,75	0,804624	-0,05462	27	0,17	0,250088	-0,07009
3	0,54	0,582284	-0,04228	28	0,57	0,611471	-0,04147
4	0,47	0,4749	-0,0049	29	0,94	0,894154	0,045846
5	0,59	0,514547	0,075453	30	0,88	0,895011	-0,01501
6	0,62	0,66301	-0,04301	31	0,71	0,632607	0,077393
7	0,64	0,5952	0,0448	32	0,75	0,740126	0,009874
8	0,35	0,320202	0,029798	33	0,89	0,885151	0,004849
9	0,46	0,414705	0,045295	34	0,45	0,402151	0,047849
10	0,66	0,714201	-0,0542	35	0,43	0,503842	-0,07384
11	0,53	0,55233	-0,02233	36	0,56	0,604389	-0,04439
12	0,73	0,657219	0,072781	37	0,72	0,715954	0,004046
13	0,78	0,855662	-0,07566	38	0,76	0,747111	0,012889
14	0,89	0,899138	-0,00914	39	0,54	0,533387	0,006614
15	0,45	0,51241	-0,06241	40	0,83	0,856239	-0,02624
16	0,67	0,745447	-0,07545	41	0,56	0,618142	-0,05814
17	0,77	0,774431	-0,00443	42	0,8	0,795159	0,004841
18	0,44	0,410835	0,029165	43	0,28	0,305724	-0,02572
19	0,56	0,535118	0,024882	44	0,8	0,820306	-0,02031
20	0,48	0,525441	-0,04544	45	0,71	0,74213	-0,03213
21	0,66	0,682068	-0,02207	46	0,66	0,698864	-0,03886
22	0,54	0,596129	-0,05613	47	1	0,951718	0,048282
23	0,84	0,859505	-0,0195	48	1	0,951718	0,048282
24	0,7	0,712668	-0,01267	49	1	0,951718	0,048282
25	0,87	0,863708	0,006292	50	1	0,951718	0,048282

На рис. 3 представлен график расчетных ( $K_{оп p}$ ) спрогнозированных ( $K_{оп c}$ ) значений коэффициента обобщенного параметра, на котором можно наглядно увидеть точность прогноза.



**Рис. 3.** Расчетные и спрогнозированные значения коэффициента обобщенного параметра

Для оценки результатов прогнозирования использовано значение средней абсолютной ошибки (7).

$$e_{MAE} = \frac{1}{n} \sum_{i=1}^n |K_{оп\ p} - K_{оп\ c}|, \quad (7)$$

где  $e_{MAE}$  – средняя абсолютная ошибка;

$K_{оп\ p}$ ,  $K_{оп\ c}$  – расчетное и спрогнозированное значения коэффициента обобщенного параметра соответственно.

Величина  $e_{MAE}$  на тестовом множестве составила 3,8 %, что в целом показывает корректность полученной модели.

## 7. SWOT-анализ результатов исследования

*Strengths.* В сравнении с аналогичными системами, основанными на детерминированных методах обработки информации, использование системы, на базе ИНС обеспечивает следующие полезные свойства систем прогнозирования:

- нелинейность;
- адаптивность;
- очевидность ответа;
- отказоустойчивость;
- масштабируемость;
- единообразие анализа и проектирования.

*Weaknesses.* Применение ИНС при решении сложных задач не всегда приводит к получению качественных решений. В настоящее время не существует какой-либо формализованной теории оптимизации структуры нейронных сетей или оценки влияния архитектуры сети на представление знаний в ней. Ответы на эти вопросы обычно получают экспериментальным путем.

*Opportunities.* Система прогнозирования, основанная на ИНС, обеспечит увеличение скорости вычисления и, как следствие, объема обрабатываемой информации за единицу времени. Это позволит уменьшить аппаратную стоимость и расширить номенклатуру выполняемых средствами судовой автоматизации функций, необходимых для обеспечения безаварийной работы СЭЭС.

*Threats.* Независимо от того, как выбирается архитектура сети, знания о предметной области выделяются ИНС в процессе обучения. Эти знания представляются в компактно распределенном виде весов синаптических связей сети. Такая форма представления знаний позволяет нейронной сети адаптироваться и выполнять обобщение, однако не обеспечивает полноценного описания вычислительного процесса, используемого для принятия решения или формирования выходного сигнала. Это приводит, как следствие, к увеличению времени, необходимого для выбора оптимальных настроек системы. Также отрицательной стороной является необходимость в дополнительных затратах на обучение персонала, обеспечивающего обслуживание данного рода систем.

## **8. Выводы**

1. Установлено, что для определения состава входных параметров нейронной сети и формирования рациональной обучающей выборки, при создании систем прогнозирования работоспособности СЭЭС на базе ИНС, можно использовать математические методы временной экстраполяции.

2. Показано, что система прогнозирования СЭЭС на базе ИНС обладает высокой аппроксимирующей способностью и позволяет обрабатывать статистическую информацию, выполняя прогнозные оценки. Это подтверждается результатами контрольного прогнозирования. При этом значение средней абсолютной ошибки прогнозирования составляет 3,8 %, что позволяет судить о возможности применения многослойных нейронных сетей при разработке систем прогнозирования работоспособности СЭЭС.

## **Литература**

1. MAIB Marine Accident Investigation Branch [Electronic resource]. – Available at: \www/URL: <http://www.maib.gov.uk>
2. Bunn, D. W. Comparative Models for Electrical Load Forecasting [Text] / ed. by D. W. Bunn, E. D. Farmer. – Wiley, 1985. – 242 p.
3. Zakariukin, V. P. Modelirovanie i prognozirovanie protsessov elektropotrebleniia na zheleznodorozhnom transporte [Text] / V. P. Zakariukin, A. V. Kriukov, N. V. Raevskii, D. A. Yakovlev; ed. by A. V. Kriukov. – Irkutsk, 2007. – 115 p.
4. Emelianov, A. S. Ekonometriia i prognozirovanie [Text] / A. S. Emelianov. – Moscow: Ekonomika, 1985. – 306 p.

5. Singh, A. K. An Overview of Electricity Demand Forecasting Techniques [Text] / A. K. Singh, I. S. Khatoon, M. Muazzam, D. K. Chaturvedi // Network and Complex Systems. National Conference on Emerging Trends in Electrical, Instrumentation & Communication Engineering. – 2013. – Vol. 3, No. 3. – P. 38–48.
6. Garde, V. D. Technological forecasting for power generation – A study using the Delphi technique [Text] / V. D. Garde, R. R. Patel // Long Range Planning. – 1985. – Vol. 18, No. 4. – P. 73–79. doi:[10.1016/0024-6301\(85\)90087-1](https://doi.org/10.1016/0024-6301(85)90087-1)
7. Venttsel, E. S. Teoriia veroiatnostei [Text]: Handbook / E. S. Venttsel. – Ed. 6. – Moscow: Vishcha shkola, 1999. – 576 p.
8. Wailly, O. Algebraic Observability Analysis of Electrical Network with Symbolic Computation: Application on MYRTE Electrical Power Plant [Text] / O. Wailly, N. Heraud, E. J. R. Sambatra // IFAC Proceedings Volumes. – 2014. – Vol. 47, No. 3. – P. 1085–1089. doi:[10.3182/20140824-6-za-1003.01782](https://doi.org/10.3182/20140824-6-za-1003.01782)
9. Gordunovsky, V. A Summation Constraint Method for Linear Programming [Text] / V. Gordunovsky // Procedia Computer Science. – 2015. – Vol. 55. – P. 246–250. doi:[10.1016/j.procs.2015.07.039](https://doi.org/10.1016/j.procs.2015.07.039)
10. Box, G. E. P. Time Series Analysis: Forecasting and Control [Text] / G. E. P. Box, G. M. Jenkins, G. C. Reinsel, G. M. Ljung. – Ed. 5. – Wiley, 2015. – 712 p.
11. Smoliak, S. A. Ustoichivye metody otsenivaniia [Text] / S. A. Smoliak, B. P. Titarenko. – Moscow: Statistika, 1980. – 208 p.
12. Alencar, R. J. N. A method to identify inrush currents in power transformers protection based on the differential current gradient [Text] / R. J. N. Alencar, U. H. Bezerra, A. M. D. Ferreira // Electric Power Systems Research. – 2014. – Vol. 111. – P. 78–84. doi:[10.1016/j.epsr.2014.02.009](https://doi.org/10.1016/j.epsr.2014.02.009)
13. Mitiushkin, K. G. Telekontrol' i teleupravlenie v energosistemah [Text] / K. G. Mitiushkin. – Moscow: Energoatomizdat, 1990. – 287 p.
14. Myzin, A. P. Metody i modeli prognozirovaniia dlia razvitiia elektroenergeticheskikh sistem v usloviiah neopredelionnosti i mnogokriterial'nosti [Text]: Dissertation of the Doctor of Technical Sciences / A. P. Myzin. – Novosibirsk, 1994. – 307 p.
15. Kozub, D. J. Multivariable Control of a Catalytic Tubular Reactor Using Both Wiener-hopf Controller Design and Internal Model Controller Design Approaches [Text] / D. J. Kozub, J. F. MacGregor, J. D. Wright // IFAC Proceedings Volumes. – 1986. – Vol. 19, No. 15. – P. 285–293. doi:[10.1016/s1474-6670\(17\)59436-7](https://doi.org/10.1016/s1474-6670(17)59436-7)
16. Singh, S. K. Several variants of Kalman Filter algorithm for power system harmonic estimation [Text] / S. K. Singh, N. Sinha, A. K. Goswami, N. Sinha // International Journal of Electrical Power & Energy Systems. – 2016. – Vol. 78. – P. 793–800. doi:[10.1016/j.ijepes.2015.12.028](https://doi.org/10.1016/j.ijepes.2015.12.028)
17. Spravochnik po tipovym programmam modelirovaniia [Text]. – Kyiv: Tehnika, 1980. – 184 p.
18. Ding, F. The model equivalence based parameter estimation methods for Box–Jenkins systems [Text] / F. Ding, D. Meng, Q. Wang // Journal of the Franklin

Institute. – 2015. – Vol. 352, No. 12. – P. 5473–5485.  
doi:[10.1016/j.jfranklin.2015.08.018](https://doi.org/10.1016/j.jfranklin.2015.08.018)

19. Alban, A. Efficient Monte Carlo methods for estimating failure probabilities [Text] / A. Alban, H. A. Darji, A. Imamura, M. K. Nakayama // Reliability Engineering & System Safety. – 2017. – Vol. 165. – P. 376–394.  
doi:[10.1016/j.ress.2017.04.001](https://doi.org/10.1016/j.ress.2017.04.001)

20. Theil, H. Applied Economic Forecasting [Text] / H. Theil. – Elsevier Science Publishing Co Inc., 1966. – 503 p.

21. Bolshov, L. A. Prognozirovaniie energopotrebleniia: sovremennye podhody i primer issledovaniia [Text] / L. A. Bolshov, M. F. Kanevskii, E. A. Savelieva et al. // Izvestiia RAN. Energetika. – 2004. – Vol. 6. – P. 74–92.

22. Wang, C. Parametric optimization of steam cycle in PWR nuclear power plant using improved genetic-simplex algorithm [Text] / C. Wang, C. Yan, J. Wang, C. Tian, S. Yu // Applied Thermal Engineering. – 2017. – Vol. 125. – P. 830–845.  
doi:[10.1016/j.applthermaleng.2017.07.045](https://doi.org/10.1016/j.applthermaleng.2017.07.045)

23. Khan Mashwani, W. Hybrid non-dominated sorting genetic algorithm with adaptive operators selection [Text] / W. Khan Mashwani, A. Salhi, O. Yeniay, H. Hussian, M. A. Jan // Applied Soft Computing. – 2017. – Vol. 56. – P. 1–18.  
doi:[10.1016/j.asoc.2017.01.056](https://doi.org/10.1016/j.asoc.2017.01.056)

24. Javidrad, F. A new hybrid particle swarm and simulated annealing stochastic optimization method [Text] / F. Javidrad, M. Nazari // Applied Soft Computing. – 2017. – Vol. 60. – P. 634–654. doi:[10.1016/j.asoc.2017.07.023](https://doi.org/10.1016/j.asoc.2017.07.023)

25. Gordienko, E. K. Iskusstvennye neironnye seti I. Osnovnye opredeleniia i modeli [Text] / E. K. Gordienko, A. A. Lukianitsa // Tehnicheskaiia kibernetika. – 1994. – No. 5. – P. 79–91.

26. Dorrer, M. G. Intuitivnoe predskazanie neurosetiami vzaimootnoshenii v gruppe [Text] / M. G. Dorrer; ed. by A. N. Gorban // Metody neuroinformatiki. – Krasnoarsk, 1998. – P. 111–129.

27. Mihailov, M. Yu. Primenenie iskusstvennykh neironnykh setei dlia kratkosrochnogo prognozirovaniia nagruzki [Text] / M. Yu. Mihailov // Metody upravleniia fiziko-tehnicheskimi sistemami energetiki sistemami energetiki v novykh usloviiah. – Novosibirsk, 1995. – P. 82–86.

28. Leikin, V. S. Sistemnyi podhod k otsenke sudovykh elektroenergeticheskikh kompleksov [Text] / V. S. Leikin, V. P. Nino // Sudostroenie. – 1974. – Vol. 3. – P. 41–44.

29. Haykin, S. Neural Networks: A Comprehensive Foundation [Text] / S. Haykin. – Ed. 2. – Prentice Hall, 1998. – 842 p.

30. Aksenov, S. V. Organizatsiia i ispol'zovanie neironnykh setei (metody i tehnologii) [Text] / S. V. Aksenov, V. B. Novoseltsev; ed. by V. B. Novoseltsev. – Tomsk: NTL, 2006. – 128 p.

31. Geman, S. Neural Networks and the Bias/Variance Dilemma [Text] / S. Geman, E. Bienenstock, R. Doursat // Neural Computation. – 1992. – Vol. 4, No. 1. – P. 1–58. doi:[10.1162/neco.1992.4.1.1](https://doi.org/10.1162/neco.1992.4.1.1)

32. Virianskii, Z. Ya. Sudovye sistemy avtomaticheskogo kontrolya (Sistemnyi podhod k proektirovaniyu) [Text] / Z. Ya. Virianskii, I. L. Kiselev, N. V. Kolesnikov. – Leningrad: Sudostroenie, 1974. – 254 p.
33. Baranov, A. P. Sudovye avtomatizirovannye elektroenergeticheskie sistemy [Text] / A. P. Baranov. – Moscow: Transport, 1988. – 328 p.
34. Gaskarov, D. V. Prognozirovaniye tehnikeskogo sostoianiia i nadezhnosti radioelektronnoi apparatury [Text] / D. V. Gaskarov, D. V. Golinkevich, A. V. Mozgalevskii. – Moscow: Sovetskoe radio, 1974. – 224 p.
35. NeuroPro: neironnye seti, metody analiza dannyh: ot issledovaniia do razrabotok i vnedrenii [Electronic resource]. – Available at: \www/URL: <http://neuropro.ru/>