

ИСПОЛЬЗОВАНИЕ МЕТОДОВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ЗАДАЧАХ ПЛАНИРОВАНИЯ РАСХОДОВ ЭЛЕКТРИЧЕСКОЙ И ТЕПЛОВОЙ ЭНЕРГИЙ

Курбацкий В.Г., Томин Н.В.

ГОУ ВПО «Братский государственный университет», 665709, Россия, г. Братск, ул. Макаренко, 40

Повышенный интерес к технологиям искусственного интеллекта со стороны научных сотрудников и инженеров, в частности и энергетиков, во многом связан со спецификой развития современных технических систем, характеризующихся термином RWC* [1]. Для электроэнергетики это во многом предопределяется усложнением топологии схем электроэнергетических систем (ЭЭС), и как следствие, усложнением формализации основных задач управления режимами. Как показывают экспериментальные исследования, эта проблема может успешно решаться в рамках RWC, где вычислительным и управляющим системам представляется возможность самостоятельно, без помощи «переводчика» - человека, воспринимать внешние воздействия и находить эффективное решение.

С позиции современных инженерных исследований в тепло- и электроэнергетике на базе методов искусственного интеллекта (МИИ) можно выделить следующие основные направления работ:

1. Нейросетевое моделирование сложных процессов в ЭЭС
2. Создание нечётких систем управления.
3. Решение оптимизационных задач с использованием генетических алгоритмов.
4. Создание интеллектуальных экспертных систем управления.
5. Применение гибридных моделей, объединяющих различные МИИ.

Экспериментальные исследования показывают [2, 3], что применение МИИ в решении задач планирования электрической и тепловой энергии позволяет получить значительно лучшие результаты, в сравнении с традиционными методиками, и в большинстве случаев предложить новые, более эффективные подходы. Рассмотрим практические примеры реализации новых технологий в решении таких задач.

Известно, что для организации эффективного функционирования электрических сетей целесообразна достоверная оценка – прогноз электрических нагрузок, а впоследствии и потеря электроэнергии [2].

Так, отклонения фактического графика нагрузок при покупке электроэнергии с оптового рынка по большей цене. В свою очередь, отклонение графика в меньшую сторону тоже карается оплатой недопоставленной электроэнергии, определяемой разницей между заявленным и фактическим потреблением по установленным расценкам.

Разработанные в настоящее время методы и модели прогнозирования можно разделить на традиционные и модели, основанные на искусственном интеллекте. Многочисленные публикации [2,4-7] свидетельствуют о том, что при прогнозе случайных процессов в энергетике наиболее популярным и эффективными, из всех МИИ, являются искусственные нейронные сети (ИНС) [4].

ИНС – это математические модели, базирующиеся на самообучающихся алгоритмах, используемые для обработки информации явления, аналогичные происходящим в нейронах живых организмов. В общем случае, ИНС представляют собой набор элементарных нейроподобных преобразователей информации – нейронов, соединённых друг с другом каналами обмена информации для их совместной работы. Важнейшей особенностью таких сетей является возможность параллельной обработки информации всеми звеньями [4]. Другое не менее важное свойство ИНС – способность к обучению и обобщению накопленных знаний. ИНС обладает чертами искусственного интеллекта. Поэтому обученная на ограниченной выборке данных сеть способна обобщать полученную информацию и достигает хороших результатов на данных, не используемых в процессе обучения.

Процесс прогнозирования электрических нагрузок (как впрочем, и большинства параметров в тепло- и электроэнергетике) на базе ИНС состоит из следующих этапов [8]:

- Подбор архитектуры ИНС.
- Выбор обучающих данных и структуры входных векторов.
- Тренинг (обучение) ИНС
- Тестирование ИНС на контрольном множестве данных и при необходимости её дообучение.
- Использование ИНС в качестве модели прогнозирования

* Real world computing – «вычисления в реальном мире»

- Возможное дообучение ИНС по истечении определённого времени, например одного года эксплуатации

Экспериментальные исследования свидетельствуют о том [2, 9], что наиболее точный прогноз электрической нагрузки выполняется многослойным персептроном (МП) (рис. 1) с обучением по методу обратного распространения ошибки. Данная архитектура ИНС позволяет наиболее эффективно воспроизводить достаточно сложные зависимости, которые сопутствуют плохо формализуемым задачам. Разработка алгоритма обратного распространения ошибки для определения весов в МП сделали эти сети наиболее применимыми в задачах прогнозирования случайных процессов.




рис.1. Многослойный персептрон.

На рисунке 2 показаны результаты суточного прогнозирования электрической нагрузки на конец апреля 1999 г. по одному из энергорайонов г. Иркутска. Средняя ошибка прогноза при этом составила 1.88%.




рис. 2. Суточный прогноз электрической нагрузки по одному из энергорайонов г. Иркутска на конец апреля 1999 г.

Качество прогнозирования оценивается показателем процентной погрешности, $MAPE^*$, определяемым в виде:

$$MAPE = \frac{P_{факт} - P_{прог}}{P_{прог}} \cdot 100\% \quad (1)$$

где $P_{факт}$, $P_{прог}$ - соответственно фактическое и прогнозное значения электрической нагрузки

Для энергопредприятия также крайне важно знать и ожидаемый процент потерь электроэнергии (ЭЭ), в электрических сетях, в особенности сверхнормативных, обслуживаемого им энергорайона, так как на основе этой информации региональная энергетическая комиссия (РЭК) формирует заданный процентный уровень для каждого отдельного энергопредприятия. Последнее, в значительной мере, влияет на финансовую деятельность энергопредприятия.

Сверхнормативные потери (СП) ЭЭ – это прямые финансовые убытки электросетевых компаний [10]. Эти потери связаны с целым рядом факторов, а именно: ослаблением контроля за потреблением ЭЭ, снижением платёжеспособности значительной части потребителей, в первую очередь населения, с ростом хищений электроэнергии, обострением проблем из-за несоответствия традиционной системы учёта ЭЭ и т.д. Экономия от снижения величины СП можно было бы направить на техническое переоснащение сетей; увеличение зарплаты персоналу; совершенствование организации передачи и распределения ЭЭ, повышение качества электроснабжения потребителей; уменьшение тарифов на ЭЭ и т.д.

Как было отмечено выше ряд структур ИНС, в частности МП, отличаются исключительными прогнозными свойствами, когда на основе обучения по предыстории возможно получение достаточно точных прогнозов необходимого параметра. В связи с этим для прогноза СП, проведённого для муниципального теплоэнергетического предприятия (МБ ТЭП) ЖКХ г. Братска, была использована нейросетевая модель на базе МП. В качестве обучающей выборки использовались ретроспективные данные за период 2000-2005 г.г. по ряду показателей, а именно:

- приобретенная ЭЭ;
- технологические потери ЭЭ;
- расход ЭЭ субабонентами;
- реализация ЭЭ;
- фактическая реализация ЭЭ;

Перед началом обучения исходная выборка была проанализирована с помощью нейросетевого алгоритма «Boxcouting», позволяющего определить статистическую значимость входных значений вышеописанных показателей, для оценки выходных значений - сверхнормативных потерь ЭЭ. Результаты такого анализа приведены на рисунке 3. Суть данного анализа состоит в том, что чем выше столбец гистограммы для данного входа – тем более значима его информация. Как явствует из рисунка 3, для прогноза на 2006 г. СП наиболее значимыми являются: величина приобретённой ЭЭ и её реализация.

* Mean Absolute Percentage Error




рис. 3. Результаты анализа статистической значимости входных значений по отношению к выходной величине показателя




рис. 4. Общая нейросетевая модель для прогноза сверхнормативных потерь ЭЭ.

Определённую трудность в осуществлении прогноза вызывал малый объём выборки, не позволяющий полноценно выявить закономерности в распределении прогнозируемых потерь. В соответствии с этим были использованы все зависимые параметры в выборке, и несколько структур ИНС, построенных на базе двухслойного персептрона (рис. 4). В данном случае задача прогнозирования решалась несколькими нейросетями, объединёнными в один функциональный блок – «малые эксперты» [1]. Поскольку прогнозы экспертов могут различаться, в работе предлагается способ получе-

ния единственного ответа. В тех случаях, когда ошибки тестирования всех экспертов практически не отличаются, можно рассчитывать среднее значение прогноза по данным прогноза ИНС в блоке «малых экспертов». В противном случае предпочтение, в рамках принятого критерия, отдаётся одному из малых экспертов. При получении общего прогноза из прогнозов «малых экспертов» для каждого месяца выделялись минимальные и максимальные значения, что априори определило доверительную апертуру (рис. 5).

Плата за потреблённую ЭЭ, для большинства бытовых потребителей, в частности населения, осуществляется, чаще всего, по одноставочному тарифу:

$$T^I = b W, \quad (2)$$

b – ставка за потреблённую ЭЭ, руб./ кВтч.

W – фактическая потреблённая ЭЭ, кВтч

На основе полученного прогноза СП, в соответствии с (2), были рассчитаны прогнозируемые убытки, которые может понести МБ ТЭП в предстоящий год.

Как уже отмечалось, сложности в планировании (прогнозе), и, в первую очередь, в анализе потерь активной ЭЭ, как правило, связаны с особенностями располагаемой информации, а именно:

- крайне приближённое описание характеристик параметров режима и сети, являющихся сложной функцией времени, например, замена графиков нагрузки их показателями;
- отсутствие достоверной информации о реальных графиках нагрузки. Использование в этой связи нормативных или типовых графиков;
- наличие погрешности измерений значений потребляемой ЭЭ.

В связи с этим авторами предложен альтернативный подход к анализу потерь ЭЭ основанный на использовании в качестве моделей расчёта ИНС. Так на базе ИНС Кохонена, проведён анализ потерь ЭЭ, как в годовом разрезе 2003 г., так и в пределах каждого месяца, для распределительных сетей 0,4-10 кВ МБ ТЭП.




рис. 5. Результаты прогнозов среднего, максимального и минимального значений сверхнормативных потерь ЭЭ по одному из населённых пунктов на 2006 г.




рис. 6. Самоорганизующаяся нейронная сеть Кохонена.

Самоорганизующаяся сеть Кохонена (SOM) [1] относится к сетям, использующих парадигму «обучения без учителя», и широко применяется для классификации (кластеризации) и распознавания образов. В общем случае нейрон Кохонена состоит из двух слоёв (рис. 6). На первый (входной) слой подаётся входная информация, и он служит для распределения входного сигнала между нейронами второго слоя.

Исходная выборка представляла собой данные о потерях активной ЭЭ в трансформаторных подстанциях (ТП) по ряду посёлков исследуемого энергорайона за 2003 год. Создание и обучение SOM проводилось в программном пакете Excel Neural Package, с использованием компоненты Kohonen Map 1.0. Входной набор включал данные по потерям ЭЭ за каждый месяц для отдельной ТП. Вследствие этого входной слой ИНС Кохонена составлял 12 нейронов (рис. 7).




рис. 7 Сеть Кохонена для кластеризации трансформаторных подстанций.

Входная выборка, нормировались по принципу среднее/дисперсия (mean/variance), выбранной посредством анализа способов нормирования. Для дополнительной обработки, уже нормированных значений данных, был использован метод главных компонент (PCA) [4], позволяющий автоматически понизить размерность входного пространства. В процессе обучения сети Кохонена были созданы карты Кохонена размерностью $2 \times 2 = 4$ нейронов, изображённую в виде диаграмм Хилтона (рис. 8). В каждом узле сетки, такой диаграммы, строится квадрат-кластер, размер которого пропорционален

числу точек данных, ближайших к данному узлу, а оттенок отражает значение соответствующего признака.




рис. 8. Пример карты Кохонена в виде диаграммы Хилтона для октября 2003 г.

В соответствии с критерием значимости потерь ЭЭ разработанная нейросетевая модель осуществила в годовом разрезе разделение нагрузок потребителей ТП исследуемого энергорайона по четырём группам. Наряду с кластеризацией, нейросетевая модель выполнила сравнительную оценку потерь активной ЭЭ по ТП для каждой из полученных групп. С этой целью в рамках каждого месяца сравнивались потери по группам, что позволило выделить месяцы с более высоким уровнем потерь. На втором этапе, с помощью дополнительной кластеризации, выделялись группы с наиболее высоким уровнем потерь ЭЭ, внутри которых анализировались отдельные ТП и выявлялись подстанции, приводящие к повышенным значениям потерь ЭЭ внутри группы (табл. 1).

Таблица 1 - Выделение очагов потерь ЭЭ при помощи кластеризации на базе сети Кохонена

Группа ТП	Подстанции, приводящие к повышенному уровню потерь ЭЭ	Месяц наибольших потерь ЭЭ
Кластер В1	ТП 14 (п. Порожский)	Октябрь
Кластер А2	ТП 196 (п. Стениха)	Май
	ТП 2, 5, 10 (п. Порожский)	Июнь
	ТП 5, 13 (п. Порожский)	Июль
	ТП 5, 13 (п. Порожский)	Август
	ТП 196 (п. Стениха)	Сентябрь

* ТП с аномально высоким уровнем потерь ЭЭ

Кроме этого для каждой рассмотренной группы, были построены графики распределения потерь по ТП в течение года (рис. 9, 10). На основе анализа данных графиков и полученных карт Кохонена, были выделены отдельные ТП с аномально высоким уровнем потерь ЭЭ.




рис. 9. Распределение потерь ЭЭ по отдельным ТП для кластера В1.




рис. 10. Распределение потерь ЭЭ по отдельным ТП для кластера А2.

Полученные результаты свидетельствуют о том, что кластер А2, а также кластер В1, включает в себя, наиболее значимые очаги потерь ЭЭ, порождённые соответствующими ТП, большая часть из которых относится к посёлку Порожский. При этом, основной причиной высоких потерь в посёлке Порожский является наличие значительных СП.

В соответствии с действующим законодательством Российской Федерации теплоснабжающие организации обязаны предоставить до начала следующего года расчёт, обосновывающий тариф на тепловую энергию на предстоящий календарный год. На основе этого расчёта РЭК формирует тариф для каждого отдельного ТЭП [3].

Известно, что расход тепловой энергии, $Q_{от}$ для целей отопления в значительной степени предопределяется температурой наружного воздуха, $t_{не}$, а именно

$$Q_{от} = q_{от} \cdot K \cdot T \quad (3)$$

где $q_{от}$ - подключённая нагрузка отопления при температуре наружного воздуха равной -43°C ; K - переводной коэффициент расчётной нагрузки на фактическую температуру наружного воздуха; T - период, за который определяется количество потреблённой тепловой энергии для отопления, в час.

В свою очередь величина K определяется по следующему выражению:

$$K = \frac{t_{вн} - t_{н.в}^{\phi}}{t_{вн} - t_{н.в}^p} \quad (4)$$

где $t_{вн}$ - температура воздуха внутри жилого помещения $+20^{\circ}\text{C}$; $t_{н.в}^p$ - расчётная температура наружного воздуха для каждого отдельного населённого пункта; $t_{н.в}^{\phi}$ - фактическая среднемесячная температура наружного воздуха за рассматриваемый период.

Поскольку расчёты производятся на перспективу, то для теплоснабжающей организации возникает задача достоверной оценки среднемесячной $t_{не}$ на предстоящий отопительный период. Получить такую информацию в подразделениях гидрометеоцентра не представляется возможным, поскольку в этом случае прогноз температуры осуществляется для больших территорий (область, район).

Естественно, ТЭП заинтересованы в достаточно точном прогнозе ожидаемой величины $t_{не}$. Данные анализа свидетельствуют о том [8], что при ошибке в определении $t_{не}$ на 1°C больше фактической температуры возможные доходы от реализации тепловой энергии для целей отопления уменьшаются на 3.44% от плана.

В МБ ТЭП ЖКХ г. Братска для прогнозирования величины $t_{не}$ по имеющимся фактическим данным за предыдущие 10 лет был использован метод наименьших квадратов (МНК) [11]. МНК – это достаточно распространённый в практике статистического оценивания подход, с помощью которого неизвестные параметры модели оцениваются путем минимизации суммы квадратов отклонений действительных (эмпирических) значений от теоретических. Основной его предпосылкой является чёткое разделение исходных переменных на зависимые и независимые. К сожалению, эмпирические данные, в частности, ретроспективные данные $t_{не}$ не всегда обладают такими свойствами, вследствие чего предпосылки МНК нарушаются. Результаты расчётов, полученные в МБ ТЭП, выявили, что при этом методе ошибка прогноза $t_{не}$ изменялась в диапазоне от 1 до 4 $^{\circ}\text{C}$. Нестационарность, неоднородность и относительная низкая точность прогноза обуславливают необходимость поиска специфических средств моделирования и применения нестандартных алгоритмов вычисления прогнозов.

В связи с этим, для повышения точности прогноза величины $t_{не}$, в работе предложен нейросетевой метод. На первом этапе, анализировались различные выборки ретроспективных данных по величине $t_{не}$, а именно:

- среднемесячные значения $t_{не}$ за предыдущие 10 лет (период 1994-2004);
- среднесуточные величины температуры за предыдущие 5 лет (период 1999-2004 г.г.).

** GRNN - обобщенно-регрессионные нейронные сети

График зависимости температуры $t_{\text{нв}}, ^\circ\text{C}$ от времени $T, \text{мес.}$. Показаны фактическая температура (черная линия с ромбами) и прогноз ИНС (красная линия с квадратами).

Время $T, \text{мес.}$	Фактическая температура $t_{\text{нв}}, ^\circ\text{C}$	Прогноз ИНС $t_{\text{нв}}, ^\circ\text{C}$
1	-16	-17
2	-13	-13
3	-9	-10
4	0	0
5	9	9
6	8	8
7	2	1
8	-6	-8
9	-21	-21

Как видно из представленной таблицы, при использовании прогноза по нейросетевому методу, потери прибыли существенно ниже, нежели при использовании метода наименьших квадратов. Так в представленном примере, с прогнозом температуры на январь 2005, Братское ТЭП, в случае исполь-

месяцы модели	январь	февраль	март	апрель	май	сентябрь	октябрь	ноябрь	декабрь
Прогноз ИНС №1, °C	-19,6	-14,4	-7,4	1,06	9,76	8,4	-0,2	-9,5	-16,3
Прогноз ИНС №2, °C	-19,5	-14,9	0,3	0,9	10,55	7,1	0,3	-8,8	-16,9
Прогноз генетической сети, °C	-17,5	-13,7	-7,09	-0,62	9,64	7,88	-0,1	-9,39	-17,3
Общий прогноз, °C	-19,6	-14,3	-7,2	1,0	9,9	7,1	-0,2	-9,2	-17,1

Таблица 3 - Результаты тестирования ИНС №1 на отопительный период 2004 г по одному из энерго-районов г. Братска

Месяцы отопительного периода	Фактическое значение температуры, °С.	Прогноз ИНС, °С	Абсолютная ошибка, °С	Относительная ошибка, %	Месяцы отопительного периода	Фактическое значение температуры, °С.	Прогноз ИНС, °С	Абсолютная ошибка, °С	Относительная ошибка, %
январь	-16,3	-16,8	0,5	3,4	сентябрь	8,4	7,9	0,5	6,1
февраль	-13,0	-12,8	0,2	1,2	октябрь	2,4	1,7	0,7	31,2
март	-8,9	-9,7	0,8	9,7	ноябрь	-5,7	-7,9	2,2	38,8
апрель	0,4	0,38	0,02	5,0	декабрь	-20,6	-20,8	0,2	1,3
май	8,6	8,5	0,1	0,8	средняя ошибка			0,6	10,8

зования прогноза нейросети, сэкономила примерно 2300€. Необходимо подчеркнуть, что экономия денежных средств наблюдается лишь в том случае если, прогноз меньше фактического значения. Несмотря на это следует особо отметить то обстоятельство, нельзя получать только «заниженные» прогнозы, чтобы на первый взгляд сэкономить деньги. Как уже подчёркивалось, от прогноза температуры наружного воздуха напрямую зависит уровень тарифа на тепловую энергию, который формируется РЭК в соответствии с представленным до начала календарного года, прогнозом значения $t_{не}$.

Таблица 4 - Сравнительный экономический расчёт эффективности прогнозирования на базе двух моделей

Экономические показатели	Модель МНК		Модель ИНС	
	расчёт	факт.	расчёт	факт.
Переводной коэффициент К	0,61	0,595	0,594	0,595
Доход от отпуска 1 Гкал Д, €/Гкал.	10,26	10,52	10,54	10,52
Полные затраты отпуска 1 Гкал З, €/Гкал	9,66	9,765	9,77	9,765
Прибыль при отпуске 1 Гкал, П, €/Гкал	0,598	0,756	0,768	0,756
Годовая прибыль, €	108,7-117,9	137,7-149,2	139,9 – 151,6	137,7-149,2
Разница между плановой и фактической прибылями, €/год	-(29020-31217)		+(2184- 2366)	

Выводы:

1. Результаты экспериментальных расчётов свидетельствуют о том, что нейросетевые методы обеспечивают более высокую точность прогноза параметров и характеристик, по сравнению с традиционными методами прогнозирования, к примеру, МНК.
2. Предложенный нейросетевой подход позволяет успешно осуществлять годовой прогноз СП с высокой точностью, даже в условиях малой предыстории, и, как следствие, рассчитывать прогнозное значение финансовых убытков энергопредприятия при наличии сверхнормативных потерь.
3. Предложен новый подход к анализу потерь ЭЭ на базе карт Кохонена, позволяющий более эффективно находить очаги потерь ЭЭ и визуализировать огромный массив информации о потерях ЭЭ в виде компактных групп и диаграмм Хилтона.
4. Величина прогноза температуры наружного воздуха тесно связана с составляющей доходов для ТЭП. Экспериментальные расчёты показали, что при ошибке в определении $t_{не}$ на 1°С больше фактической температуры доходы от реализации тепловой энергии для целей отопления уменьшаются на 3.44% от плана.
5. Применение нейросетевых моделей в задаче прогнозирования температуры наружного воздуха позволило получить достаточно низкую среднюю ошибку прогноза, не превышающую 1°С.
6. Расчёт, проведённый для котельной г. Братска показал, что, в январе 2005 г., МБ ТЭП, при использовании МНК, потеряло в среднем **30000 €/год**. В то же время использование прогноза ИНС позволило бы не только снизить потери

прибыли, но и сэкономить около 2300 € в год.

ЛИТЕРАТУРА

- [1]. *Нейроинформатика* / А.Н. Горбань, В.Л. Дунин-Барковский, А.Н. Кирдин и др. – Новосибирск: Наука. Сибирское предприятие РАН, 1998. – 296 с.
- [2]. Курбацкий В.Г., Томин Н.В., Шуманский В.Б. *Применение нейросетевых моделей в задаче формирования тарифов на тепловую и электрическую энергию* / Энергетика: управление, качество и эффективность использования энергоресурсов: Сборник трудов четвертой Всероссийской научно-технической конференции с международным участием в 2 т. Благовещенск: издательство Амурского государственного университета, 2005. С. 32-38
- [3]. Шуманский В.Б., Курбацкий В.Г., Томин Н.В. *Прогнозирование температуры наружного воздуха на базе модели искусственной нейронной сети*. Естественные и инженерные науки – развитию регионов: Материалы межрегиональной научно-технической конференции. – Том 2. – Братск: ГОУ ВПО «БрГУ», 2005. С. 4 - 14.
- [4]. Оссовский С. *Нейронные сети для обработки информации* / Пер. с польского И.Д. Рудинского. – М.: Финансы и статистика, 2004. – 344 с.
- [5]. *Новые информационные технологии в задачах оперативного управления электроэнергетическими системами*. – Екатеринбург УрО РАН, 2002, 205 с.
- [6]. Манусов В.З., Мунхжаргал С. *Оперативное прогнозирование нагрузки с использованием нейросетевого алгоритма*. В 38 Вестник УГТУ – УПИ. Энергосистема: управление, качество, конкуренция: Сборник докладов II Всероссийской научно технической конференции: ГОУ ВПО УГТУ – УПИ, 2004, №12 (42) С. 190-192
- [7]. Kurbatsky V.G, Tomin N.V. *The employment of new information technology on the problems of power network control*. International Scientific-Practical Conference “Communication-2004”, Kirgizkaya republic, Bishkek, 2004. P.P. 81-86
- [8]. Курбацкий В.Г., Томин Н.В. *Краткосрочное прогнозирование электрической нагрузки с использованием новых информационных технологий*/ Вестник Амурского государственного университета. Выпуск 27, 2004. С. 48-51
- [9]. Глазунова А.М. *Краткосрочное прогнозирование нагрузок с использованием ИНС в составе подсистемы ОУР*. Современные программные средства для расчетов и оценивания состояния режимов электроэнергетических систем: Сборник докладов Второго международного научно-

практического семинара. – Новосибирск: ИДУЭС, 2002. С. 78 – 85

- [10]. *Снижение потерь электроэнергии в электрических сетях*. Динамика, структура, методы анализа и мероприятия. / В.Э. Воротицкий, М.А. Калинкина, Е.В. Комкова, В.И. Пятигор. Энергосбережение, 2005 №2. С. 90-94.
- [11]. Зоркальцев В.И. *Метод наименьших квадратов (геометрические свойства, альтернативные подходы, приложения)*. – Новосибирск: Наука. Сиб. Изд. Фирма РАН, 1995.



Курбацкий Виктор Григорьевич, родился 27 мая 1949 г. в г. Комсомольск-на-Амуре (Россия, Хабаровский край), доктор технических наук профессор кафедры Систем электроснабжения ГОУ ВПО «Братский государственный университет». В 1997 году в Сибирском энергетическом институте СО РАН (г. Иркутск) защитил докторскую диссертацию на тему «Мониторинг качества электроэнергии в электрических сетях России для выбора мероприятий по обеспечению электромагнитной совместимости». Член-корреспондент Сибирской АН высшей школы, член Международного исследовательского института инженеров-электриков (г. Нью-Йорк).

Профессор Курбацкий является автором нескольких монографий и учебных пособий и более 200 научных работ



Томин Никита Викторович, родился 18 декабря 1982г. в городе Братске (Россия, Иркутская область), аспирант кафедры Систем электроснабжения ГОУ ВПО «Братский государственный университет». В 2000 г. поступил в БрГУ на специальность «Электроэнергетические системы и сети». Участвовал во всероссийских и международных конференциях, в то числе и за рубежом. В 2004 г. получил диплом второй степени на международной студенческой конференции «Студент и научно-технический прогресс» (г. Новосибирск). По окончании университета защитил дипломный проект на тему использования методов искусственного интеллекта в электро-энергетических задачах.

Господин Томин специализируется в области использования новых информационных технологий в оперативно-диспетчерском управлении энергосистемами. На данный момент является автором и соавтором более 15 научных работ.