

УДК 621.316.1

Л. Н. Добровольская, к. т. н., доц.; В. И. Волынец, И. А. Бандура, к. т. н.**МНОГОФАКТОРНОЕ ПРОГНОЗИРОВАНИЕ ПОТРЕБЛЕНИЯ
ЭЛЕКТРОТЕХНИЧЕСКИХ КОМПЛЕКСОВ УГОЛЬНЫХ ШАХТ ДЛЯ
ПЛАНИРОВАНИЯ ИХ ЭНЕРГОЭФФЕКТИВНЫХ РЕЖИМОВ**

Статья посвящена решению актуальной научно-прикладной задачи планирования энергоэффективных режимов электротехнических комплексов угольных шахт за счет развития и усовершенствования математических моделей и методов многофакторного прогнозирования их электропотребления с учетом технологических характеристик.

Ключевые слова: планирование энергоэффективных режимов, прогнозирование электропотребления, электротехнический комплекс, угольные шахты, нейросети, многослойный персептрон.

Введение

Состояние экономики Украины сегодня характеризуется деформированной структурой производства, в которой высокий удельный вес составляют технологии энергоемких и материалоемких видов продукции [1], поэтому решение проблем повышения эффективности промышленных комплексов возможно лишь при существенном снижении энергозатрат на производство единицы продукции. Существенно энергоемкая структура промышленного производства, критическая зависимость топливно-энергетического комплекса от снабжения энергоносителей из России, высокая изношенность основных производственных фондов и низкий уровень экологической безопасности предприятий обуславливают первоочередную необходимость средне- и долгосрочного планирования и прогнозирования объемов энергопотребления [1, 2].

Важной отраслью топливно-энергетического комплекса (ТЭК) Украины является угольная промышленность. Актуальность ее функционирования обусловлена тем, что уголь – единственный национальный энергоноситель, который способен обеспечить энергетическую безопасность и удовлетворить существующие нужды за счет собственных ресурсов [3].

Для обеспечения рентабельности угольной промышленности необходимы внедрение энергосберегающих технологий и повышение эффективности использования электрической энергии электротехническими комплексами угольных шахт, что позволит уменьшить себестоимость добычи угля и повысить его качество [4].

В связи со структурной перестройкой экономики Украины существенным образом возрастает роль перспективного планирования развития производственных систем, т.е. научно обоснованных прогнозов [5]. Главными функциями прогнозирования являются выявление и анализ закономерностей и тенденций потребления электрической энергии; оценивание влияния этих тенденций в будущем; предположение ситуаций, которые требуют решения; выявление возможных альтернатив развития в перспективе; накопление информации для обоснованного выбора направления разработки оптимальных плановых решений.

Без прогнозирования невозможно эффективное перспективное планирование потребления электроэнергии, поскольку оно должно осуществляться с учётом темпов и пропорций развития, определенных на перспективу.

Во время разработки прогнозов и перспективных планов потребления электроэнергии необходимо учитывать фактор неопределенности, обусловленный тем, что на энергоэкономические процессы влияют различные факторы. Вследствие этого нет полного совпадения поставленной цели и окончательных результатов.

Таким образом, решение задачи повышения рентабельности угольной отрасли Украины

требует разработки нового организационно-методического обеспечения, дальнейшего совершенствования системы планирования и мониторинга электропотребления электротехнических комплексов угольных шахт, за счет чего станет возможным переход к эффективному энергопотреблению. Исходя из этого, статья посвящена усовершенствованию математических моделей и методов многофакторного прогнозирования электропотребления угольных шахт для решения задачи планирования их энергоэффективных режимов.

Классификация электротехнических комплексов угольных шахт по эффективности использования электроэнергии

Энергетическая эффективность производства – одна из основных составляющих общей эффективности (прежде всего, экономической, что обусловлено ростом цен на энергоносители). Оценивание ее в целом по отрасли, по отдельным угледобывающим предприятиям, по производственным процессам является очень важным, поскольку позволяет выявить резервы повышения эффективности функционирования предприятий.

Показателем, который характеризует эффективность использования электрической энергии, является ее удельное потребление. Эффективность функционирования любой производственной системы в современных условиях в большинстве случаев определяется состоянием ее энергетического хозяйства, поскольку энергоресурсы составляют большую долю в себестоимости любой продукции промышленного предприятия [5].

Контрольные значения удельного потребления электроэнергии определяют в целом для отдельного угольного объединения. В связи с тем, что угольные шахты находятся в разных горно-геологических условиях, имеют разное оборудование и т.п., целесообразно идентифицировать однородные классы объектов, для которых определяют показатели эффективности потребления электроэнергии.

В случае с угольными шахтами нужно учитывать горно-геологические условия, влияющих на их работу. Задача классификации электротехнических комплексов угольных шахт по степени однородности может быть решена с использованием методов Чекановского [7] и кластерного анализа [8].

Математическое формулирование задачи. Пусть задана выборка предварительно обработанных векторов данных $\{x_p\}$. Пространство векторов данных обозначено E . Каждому классу будет соответствовать некоторое ядро a . Пространство ядер обозначено A . Для каждого $x \in E$ и $a \in A$ определяют степень близости $d(x, a)$. Для каждого набора из k ядер $a_1, \dots, a_k$ и любого разбиения $\{x_p\} = P_1 \cup P_2 \cup \dots \cup P_k$ на k классов определяют критерий качества [7]:

$$D = D(a_1, a_2, \dots, a_k, P_1, P_2, \dots, P_k) = \sum_{i=1}^k \sum_{x \in P_i} d(x, a_i). \quad (1)$$

Нужно найти набор $a_1, \dots, a_k$ и разбиение $\{x_p\}$, которые минимизируют D .

На каждом шаге и этапе алгоритма уменьшается критерий качества D , отсюда вытекает сходимость алгоритма – после конечного количества шагов разбиения $\{x_p\}$ уже не изменяется.

В качестве технологических параметров, которые существенно влияют на уровень энергетической эффективности угольных предприятий, были отобраны такие: X_1 – годовой объем добычи полезных ископаемых, т; X_2 – годовой уровень проведения подготовительных выработок, м; X_3 – среднединамическая мощность пластов полезных ископаемых, м; X_4 – среднегодовой приток воды в шахту, м³/ч; X_5 – средняя численность производственного персонала, чел.; X_6 – глубина залегания пластов, м; X_7 – количество угольных пластов,

которые разрабатывают, шт.; X_8 – газонасыщенность пластов, $\text{м}^3/\text{т}$; X_9 – установленная мощность основного шахтного оборудования (ОШО), кВт.

Метод предусматривает выполнение следующих этапов:

Этап 1. Формирование матрицы наблюдений.

Имея множество из m элементов, которые описаны n признаками, каждую единицу можно интерпретировать как точку n -мерного пространства с координатами, равными значениям n признаков рассматриваемого объекта. Матрица наблюдений имеет следующий вид:

$$X = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1k} & \dots & x_{1n} \\ x_{21} & x_{22} & \dots & x_{2k} & \dots & x_{2n} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ x_{i1} & x_{i2} & \dots & x_{ik} & \dots & x_{in} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ x_{m1} & x_{m2} & \dots & x_{mk} & \dots & x_{mn} \end{bmatrix}, \quad (2)$$

где m – количество шахт; n – количество технологических параметров; x_{ik} – значение признака k для единицы i .

Таблица 1

Пример совокупности годовых технологических параметров для угольных шахт

Порядковый номер шахты	Электропотребление, кВт·ч	Технологические параметры								
		Годовой объем добычи полезного ископаемого, т	Проведение подготовительных выработок, м	Среднединамическая мощность пластов, м	Среднегодовой приток воды, $\text{м}^3/\text{ч}$	Среднее количество работников, чел.	Глубина залегания полезного ископаемого, м	Количество угольных пластов, шт.	Газонасыщенность пластов, $\text{м}^3/\text{т}$	Установленная мощность ОШО, кВт
1	2	3	4	5	6	7	8	9	10	11
1	14201712	47022	537	1,28	142	728	370	2	11,4	492
2	9434076	121105	1891	1,14	243	828	380	1	4,7	382
...										
13	16730100	452800	2601	1,18	31,98	1145	495	2	4,6	550

Этап 2. Для значений, включенных в матрицу наблюдений, необходимо выполнить нормализацию признаков, поскольку они являются неоднородными. Стандартизацию признаков выполняет по выражениям:

$$z_{ik} = \frac{x_{ik} - \bar{x}_k}{s_k}, \quad (3)$$

причем $\bar{x}_k = \frac{1}{m} \sum_{i=1}^m x_{ik}$; $s_k = \sqrt{\frac{1}{m} \sum_{i=1}^m (x_{ik} - \bar{x}_k)^2}$,

где $k = 1, 2, \dots, n$; x_{ik} – значение признака k для единицы i ; $\bar{x}_k$ – среднее арифметическое значений признака k ; s_k – стандартное отклонение признака k для единицы i .

Этап 3. Расчет элементов матрицы расстояний с учетом всех элементов матрицы

наблюдений по выражению:

$$d_{rs} = \frac{1}{n} \sum_{k=1}^n |z_{rk} - z_{sk}| \quad (r, s = 1, 2, \dots, m). \quad (4)$$

Этап 4. Следующим этапом являются отображения матрицы расстояний в графическом виде. Для этого выделяют два класса объектов, которые имеют такие графические обозначения:



Внесение в матрицу расстояний соответствующих графических символов позволяет получить неупорядоченную диаграмму Чекановского. Для выявления групп однотипных объектов необходимо выполнить перестановки столбцов и строк. Процесс перемещения строк и соответствующих им столбцов ведется до момента получения упорядоченной диаграммы (табл. 2), в которой сосредоточения знаков, соответствующих наименьшим расстояниям, размещены вдоль главной диагонали.

Таблица 2

Упорядоченная диаграмма Чекановского

Номер шахты	Номер шахты												
	1	3	10	4	11	2	9	12	5	6	7	8	13
1	■	■	■	■	■	■	■	■	■	■	■	■	■
3	■	■	■	■	■	■	■	■	■	■	■	■	■
10	■	■	■	■	■	■	■	■	■	■	■	■	■
...													
5	■	■	■	■	■	■	■	■	■	■	■	■	■
6	■	■	■	■	■	■	■	■	■	■	■	■	■
7	■	■	■	■	■	■	■	■	■	■	■	■	■
8	■	■	■	■	■	■	■	■	■	■	■	■	■
13	■	■	■	■	■	■	■	■	■	■	■	■	■

Исходя из результатов анализа (табл. 2), можно выделить четыре класса угольных шахт: первый класс – 1, 3, 10; второй – 4, 11; третий – 2, 9, 12; четвертый – 5, 6, 7, 8, 13. Следует отметить, что применение этого метода не требует сложных математических процедур. Объекты при небольших объемах информации легко поддаются классификации, что позволяет использовать метод для предварительной классификации энергетических объектов.

Нейросетевое моделирование электропотребления электротехнических комплексов угольных шахт на основе неупорядоченного множества исходных данных

Для эффективного прогнозирования электропотребления сложных электротехнических комплексов обязательным является учет связей между потреблением электроэнергии и основными технологическими факторами [5]. Следовательно, построение искусственной нейронной сети (ИНС) необходимо вести с учетом набора информативных технологических параметров.

Пусть технологические параметры конкретной угольной шахты, а также годовая добыча полезных ископаемых заданы вектором параметров $x^s \in X$, который имеет N_l

компонентов. Компоненты обозначают нижним индексом: $x^s = (x_1^s, \dots, x_{N_l}^s)^T$. Решением задачи будет множество векторов $\{y^1 \dots y^S\}$ электропотребления. Каждый вектор y^s имеет N_0 компонентов: $y^s = f(x^s)$, где $s = 1 \dots S$ – номер образа. Нейронная сеть формирует отображение $X \rightarrow Y$ для $\forall x \in X$, которое является отображением произвольного количества точек:

$$\begin{bmatrix} x^1 \rightarrow y^1 \\ \dots \\ x^S \rightarrow y^S \end{bmatrix}, \quad (5)$$

где множество векторов $x^1 \dots x^S$ – формализованное условие задачи, а множество $y^1 \dots y^S$ – формализованное решение.

Нейросетевое моделирование выполняли по данным об электропотреблении 13 шахт ГП «Волиньвугілля» и ГП «Львіввугілля» за шесть лет (2009 – 2013 гг.). На вход подавали технологические параметры, влияющие на электропотребление шахт (табл. 1), значения которых зафиксированы за тот же период.

Перед началом прогнозирования была выполнена процедура масштабирования данных с использованием пакета *STATISTICA Neural Networks* [9] минимаксной функцией: она находит минимальное и максимальное значения переменной по обучающему множеству и выполняет линейное преобразование (с применением коэффициентов масштаба и сдвига) таким образом, чтобы значения находились в диапазоне $[-1, 1]$. Перерасчет значений признаков x для i -го примера в интервал $[a, b]$ осуществлялся согласно выражению [9]:

$$\tilde{x}_i = \frac{(x_i - x_{\min}) \cdot (b - a)}{(x_{\max} - x_{\min})} + a, \quad (6)$$

где $x_{\min}, x_{\max}$ – минимальное и максимальное выборочное значение признака.

В качестве прогнозной модели был выбран многослойный персептрон, который имеет следующую архитектуру: $N_i - N_j - N_k$, где $N_i = 9$ – количество нейронов во входном слое; $N_j = 10$ – количество нейронов в скрытом слое; $N_k = 1$ – количество нейронов в выходном слое (рис. 1).

Функционирование нейрона для выходного слоя определяют соотношением [10]:

$$y_k^{(2)}(t) = \varphi \left(\sum_{l=1}^j w_{lk}^{(2)}(t) y_l^{(1)}(t) + b_k^{(2)} \right), \quad (7)$$

где $w_{lk}^{(2)}$ – вес связи l -го выхода нейрона скрытого слоя с k -ым нейроном выходного слоя; $b_k^{(2)}$ – порог k -го нейрона выходного слоя; $\varphi(\bullet)$ – функция активации нейрона.

В качестве функции активации для всех слоев выбрана сигмоидная функция:

$$\varphi(y^{(L)}(t)) = \frac{1}{1 + \exp(-a y^{(L)}(t))}, \quad (8)$$

где a – параметр наклона сигмоидной функции.

Обучение нейронной сети сводится к минимизации среднеквадратической погрешности. Настройка весов $w_{ij}^{(1)}$ и $w_{jk}^{(2)}$ проводится после подачи на нейрон каждого примера (последовательный режим обучения). Настройка весов слоя L осуществляется согласно выражению [10]:

$$w_{ij}^{(L)}(t+1) = \alpha w_{ij}^{(L)}(t) + \eta \delta_j^{(L)}(t) y_j^{(L)}(t), \quad (9)$$

где η – параметр, отвечающий за скорость обучения; α – постоянная момента ($\alpha = 1$); $\delta_j^{(L)}$ – локальный градиент j -го нейрона слоя L .




Рис. 1. Архитектура нейронной сети

Локальный градиент для выходного слоя:

$$\delta_k^{(2)}(t) = e_k(t), \quad (10)$$

где $e_k(t)$ – погрешность k -го нейрона выходного слоя; а для скрытого слоя:

$$\delta_j^{(1)}(t) = \sum_{l=1}^k \delta_l^{(2)}(t) w_{jl}^{(2)}(t) y_j^{(1)}(t). \quad (11)$$

Обучение нейронной сети было проведено в два этапа: первый этап – по алгоритму обратного распространения погрешности (100 итераций), второй этап – по методу сопряженных градиентов (360 итераций). Контрольная погрешность составила 3,06%, а учебная – 3,89%.

Результаты прогнозирования электропотребления электротехнических комплексов угольных шахт нейронной сетью приведены в табл. 3.

Анализируя данные табл. 3, можно утверждать, что выбранная нейронная сеть обеспечивает достаточную адекватность прогнозирования потребления электроэнергии на шахте (средняя относительная погрешность прогнозирования на 2013 год составила 3,5%).

Таблица 3

Результаты прогнозирования на 2013 год

Номер шахты	Название шахты	ФЭП, кВт ч	ПЭП, кВт ч	Относительная погрешность, %
1	Шахта №1 НВ	14201712	14732066	3,6
2	«Бужанська»	9434076	9522435	1,6
3	Шахта №5 НВ	4907198	5038191	2,6
4	Шахта №9 НВ	10298560	11133578	7,5
5	«Великомостівська»	11750028	12447064	5,6
6	«Бендюзька»	11689227	11807300	1,0
7	«Межірічанська»	17094030	18360934	6,9
8	«Відродження»	17176641	17350142	1,0
9	«Лісова»	22264800	23535729	5,4
10	«Зарічна»	16099488	16683407	3,5
11	«Візейська»	17729496	18821121	5,8
12	«Степова»	42022410	42220848	0,47
13	«Червоноградська»	16730100	16933300	1,2

Примечание: ФЭП – фактическое электропотребление; ПЭП – прогнозируемое электропотребление.

При условии имеющегося плана добычи угля и других технологических параметров полученная на основе ИНС многофакторная модель электропотребления является адекватной и приемлемой для планирования на год потребления электроэнергии для каждой угольной шахты и всего угольного предприятия. Но для улучшения качества прогнозной модели нужно осуществить предварительную классификацию угольных шахт методами кластерного анализа с учетом технологических параметров, которые влияют на уровень их энергетической эффективности.

Нейросетевое моделирование электропотребления электротехнических комплексов угольных шахт на основе упорядоченного множества исходных данных

Нейронные сети имеют способность адаптироваться к изменениям окружающей среды. Повышение адаптивности системы обеспечивает ее устойчивость в нестационарной среде. Для использования преимуществ адаптивности основные параметры системы должны быть довольно стабильными, чтобы можно было не учитывать внешние помех, и довольно гибкими, чтобы обеспечить реакцию на важные изменения среды.

Для обеспечения адаптивности предложенной прогнозной модели выполнен перебор перечня нейросетевых конфигураций и выбор наилучшей по критериям минимума погрешности на выходе сети и максимума ее производительности.

На каждом шаге алгоритма обучения рассчитывали погрешность для всего набора наблюдений из контрольного множества и сравнивали с погрешностью на обучающем множестве. Как правило, погрешность на контрольном множестве превышает погрешность на обучающем. Но важен не сам факт отличия, а тенденция изменения погрешностей.

Тестовое множество использовали после завершения обучения для расчета производительности полученной сети и ее погрешности на новых данных. Качественная сеть имеет одинаково низкую погрешность на всех трех подмножествах.

Для каждого из четырех классов угольных шахт, выделенных на основании предварительной классификации с помощью *STATISTICA Neural Networks*, были построены и выбраны наилучшие модели нейронных сетей.

Выбор наилучшей архитектуры нейронной сети для прогнозирования годового электропотребления электротехнических комплексов угольных шахт Львовско-Волинского бассейна для каждого из классов представлен на рис. 2 – 5.






Рис. 2. Архитектура нейронной сети для прогнозирования электропотребления угольных шахт 1 класса: а) структура и тип ИНС; б) график зависимости прогнозируемых значений от действительных




а)




б)

Погрешности:
учебная – 1,7%;
контрольная – 0,3%;
тестовая – 5,6%

Рис. 3. Архитектура нейронной сети для прогнозирования электропотребления угольных шахт 2 класса:
а) структура и тип ИНС; б) график зависимости прогнозируемых значений от действительных




а)




б)

Погрешности:
учебная – 1,67%;
контрольная – 4,64%;
тестовая – 2,69%

Рис. 4. Архитектура нейронной сети для прогнозирования электропотребления угольных шахт 3 класса:
а) структура и тип ИНС; б) график зависимости прогнозируемых значений от действительных



а)



б)

Погрешности:
учебная – 5,15%;
контрольная – 3,43%;
тестовая – 6,14%

Рис. 5. Архитектура нейронной сети для прогнозирования электропотребления угольных шахт 4 класса:
а) структура и тип ИНС; б) график зависимости прогнозируемых значений от действительных

Как видно из рис. 2 – 5, качество прогноза электропотребления угольных шахт улучшилось за счет разбита угольных шахт на однородные классы и выбора соответствующих конфигураций нейронных сетей для отдельных классов электротехнических комплексов.

Выводы

1. Эффективность потребления электрической энергии электротехническими комплексами угольных шахт зависит от ряда факторов, из которых можно выделить экономическую, техническую и технологическую группы. Показано, что оценивание степени влияния этих факторов на эффективность электропотребления необходимо выполнять с помощью

экспертно-статистической процедуры классификации.

2. Прогнозирование годового электропотребления угольных шахт на основе неупорядоченного множества исходных данных с помощью искусственных нейронных сетей показало, что для обеспечения надлежащей точности необходимо проводить предварительное деление электротехнических комплексов угольных шахт на однородные классы по энергоэффективности и технологическим параметрам. Для повышения качества формирования прогнозной модели необходимо подбирать ее архитектуру отдельно для каждого класса.

2. Моделирование годового электропотребления угольных шахт на основе упорядоченной системы объектов и множества исходных данных с помощью искусственных нейронных сетей позволило получить погрешность прогноза на уровне 3 – 4 %.

СПИСОК ЛИТЕРАТУРЫ

1. Енергетична стратегія України на період до 2030 р. [Електронний ресурс]: [Затверджено Розпорядженням Кабінету Міністрів України від 15.03.2006 р. № 145-р.]. – К., 2006. – 129 с. – Режим доступу: <http://www.ukrenergo.energy.gov.ua/ukrenergo/control/uk/archive/docview?typeld=44577>. – Назва з екрана.
2. Енергоефективність та відновлювальні джерела енергії / [під заг. ред. А. К. Шидловського]. – К.: Українські енциклопедичні знання, 2007. – 560 с.
3. Микитенко В. В. Енергоефективність промислового виробництва / Микитенко В. В. – К.: Об'єднаний інститут економіки НАН України, 2004. – 282 с.
4. Паливно-енергетичний комплекс України в контексті глобальних енергетичних перетворень / [А. К. Шидловський, Б. С. Стогній, М. М. Кулик та ін.]. – К.: Українські енциклопедичні знання, 2004. – 468 с.
5. Розен В. П. Прогнозирование показателей и классификация состояния энергетической безопасности региона / В. П. Розен, А.-М. М. Танский // Энергетика: економіка, екологія. – 2005. – № 2. – С. 101 – 109.
6. Праховник А. В. Энергосберегающие режимы электроснабжения горнодобывающих предприятий / Праховник А. В., Розен В. П., Дегтярев В. В. – М.: Недра, 1985. – 232 с.
7. Плюта В. Сравнительный многомерный анализ в эконометрическом моделировании / Плюта В.; пер. с польск. В. В. Иванова. – М.: Финансы и статистика, 1989. – 175 с.
8. Сошникова Л. А. Многомерный статистический анализ в экономике / Сошникова Л. А., Тамашевич В. Н., Уэбе Г.; под ред. В. Н. Тамашевича. – М.: ЮНИТИ-ДАНА, 1999. – 598 с.
9. Боровиков В. П. Нейронные сети. STATISTICA Neural Networks. Методология и технологии современного анализа данных / Боровиков В. П. – М.: Радио и связь, 2008. – 392 с.
10. Новосельцев И. В. Применение многопроцессорных систем для реализации многослойного персептрона / И. В. Новосельцев, Н. Г. Аксак // Наук. збірник «Радіоелектроніка. Інформатика. Управління». – 2008. – № 1. – С. 108 – 111.

Добровольская Любовь Наумовна – к. т. н., доцент, заведующий кафедрой электроснабжения, e-mail: dobro@gmail.com.

Волынец Владислав Игоревич – ассистент кафедры электроснабжения, e-mail: vvi76@mail.ru.

Бандура Ирина Александровна – к. т. н., доцент кафедры электроснабжения.
Луцкий национальный технический университет.