

ПЛОВДИВСКИ УНИВЕРСИТЕТ „ПАИСИЙ ХИЛЕНДАРСКИ“

ФАКУЛТЕТ ПО МАТЕМАТИКА И ИНФОРМАТИКА

КАТЕДРА „КОМПЮТЪРНА ИНФОРМАТИКА“

Костадин Георгиев Йотов

**Моделиране на невро-кибернетична система за прогнозиране
на потреблението на електрическата енергия**

Автореферат

на дисертационен труд за присъждане на образователна и научна степен „Доктор“

по област на висшето образование 4. Природни науки, математика и информатика

в професионално направление 4.6. Информатика и компютърни науки

докторска програма „Информатика“

Научен ръководител: доц. д-р Емил Хаджиколев

Пловдив, 2022 г.

Дисертационният труд е обсъден и насочен за защита от катедрения съвет на катедра „Компютърна информатика“ на Факултета по математика и информатика при Пловдивския университет „Паисий Хилендарски“ на 01.04.2022 г.

Дисертационният труд съдържа 179 страници. Библиографията включва 119 източника. Броят на авторските публикации по темата на дисертационния труд е 6.

Защитата на дисертационния труд ще се състои на г. от ч. в Заседателна зала, Нова сграда на Пловдивския университет, бул. „България“ № 236.

Материалите по защитата са на разположение на интересувалите се в Деканата на ФМИ – каб. 330 в Нова сграда на ПУ „Паисий Хилендарски“, всеки работен ден от 8:30 до 17:00 часа.

Автор: Костадин Георгиев Йотов

Заглавие: Моделиране на невро-кибернетична система за прогнозиране на потреблението на електрическата енергия

Пловдив, 2022 г.

Съдържание

Използвани съкращения.....	4
УВОД.....	5
ГЛАВА I. ПРОГНОЗИРАНЕ НА ЕЛЕКТРОПОТРЕБЛЕНИЕТО. СЪСТОЯНИЕ НА НАУЧНИТЕ ИЗСЛЕДВАНИЯ.....	8
Структура на националната енергийна система	8
Компоненти на ефективното управление на НЕЕС	9
Фактори, влияещи върху потреблението на електрическата енергия	9
Състояние на научните изследвания	9
ГЛАВА II. СТАТИСТИЧЕСКИ И ЧИСЛЕНИ МЕТОДИ ЗА ПРОГНОЗИРАНЕ.....	10
Корелационен и регресионен анализ.....	11
Интерполация и екстраполация	11
Времеви редове.....	12
Изводи	13
ГЛАВА III. ИЗПОЛЗВАНЕ НА ИЗКУСТВЕНИ НЕВРОННИ МРЕЖИ ЗА ПРОГНОЗИРАНЕ	13
Изкуствени неврони и връзката им с биологичния първообраз	13
Изкуствени невронни мрежи.....	14
Работа с ИНМ в MatLab	15
Прогнозиране на факторите и електропотреблението с ИНМ	18
Изводи	18
ГЛАВА IV. НЕВРО-КИБЕРНЕТИЧНА СИСТЕМА ЗА ПРОГНОЗИРАНЕ.....	19
Проектиране на НКС	19
Реализация на НКС.....	21
Прогнозиране с НКС.....	22
Прогнозиране на други величини с НКС	23
Изводи	24
ГЛАВА V. ОПТИМИЗИРАНЕ НА НКС	25
Параметри, влияещи на броя на невроните в скрития слой	25
Формула за горна граница на невроните в НМ с един скрит слой, при обучение, основано на алгоритъма на Гаус и Нютон	26
Горна граница на броя на невроните при мрежи с r скрити слоя	26
Изводи	26
ЗАКЛЮЧЕНИЕ	27
Приноси	28

Апробация	28
Списък с публикации по темата на дисертационния труд.....	29
Забелязани цитирания.....	29
БИБЛИОГРАФИЯ.....	30

Използвани съкращения

- ЕЕС - Електроенергийна система
- НЕЕС - Национална електроенергийна система
- НМ - Невронна мрежа
- ИНМ - Изкуствена невронна мрежа
- НКС - Невро-кибернетична система
- ВР - Времеви редове

Увод

Прогнозирането е процес, при който може да се предвиди напълно или частично развитието във времето на дадена скаларна или комплексна величина. В съвременния свят, движен от икономиката, предвидимостта на различни икономически параметри дава усещане за сигурност, възможност за по-добро планиране на дейностите и необходимите ресурси, намаляване на загубите, както и планиране на цялостното развитие на дадена система – държава, фирма, семейство и др.

Енергетиката е движеща сила на икономиката. Създаването на краткосрочни и дългосрочни прогнози за различни аспекти в производството и консумация на електрическа енергия дава възможност на производителите да планират по-добре използването на съществуващите и изграждането на нови мощности, а на потребителите – да адаптират поведението си в съответствие с очакваните бъдещи промени. Работата в настоящото изследване е насочена към прогнозиране на потреблението на електрическа енергия в Националната електроенергийна система на България.

Основен предмет на научното изследване е възможността за прогнозиране на електропотреблението в Националната електроенергийна система на България.

Основна цел на настоящото изследване е създаването на прототип на автоматизирана софтуерна система за прогнозиране на електропотреблението.

Една такава система трябва да включва автоматизиран избор на ефективни методи за прогнозиране както на отделните фактори, така и на комплексната зависима от тях величина. При това, тя би могла да бъде използвана и за прогнозиране на други величини.

За постигане на целите на научното изследване са формулирани следните основни задачи:

Задача 1. Да се предложат и реализират алгоритми за прогнозиране на електропотреблението.

Задача 2. Да се изгради прототип на автоматизирана невро-кибернетична система (НКС) за прогнозиране на електропотреблението, използваща създадените алгоритми.

Задача 3. Да се проведат експерименти за верификация на изградената НКС и да се предложат методи за оптимизацията ѝ.

При изпълнение на поставените задачи се следват **няколко основни етапа:**

- 1) Проучване на предметната област и анализ на научните изследвания;
- 2) Прилагане на статистически и числени методи за анализ на влиянието на основните фактори върху потреблението на електрическа енергия в България, както и прогнозиране на стойностите на факторите;
- 3) Използване на невронни мрежи за прогнозиране както на отделните фактори, така и на потреблението на електроенергия чрез един или повече фактори;
- 4) Изграждане на цялостна НКС за прогнозиране на потреблението на електроенергия;
- 5) Тестване, оптимизиране и подобрене на работата на създадената система.

В общия случай, решаването на всяка една задача за прогнозиране се извършва по сходен начин, който може да бъде сведен до няколко етапа – събиране и обработка на данни, проучване на методите за решение, решение, анализ и оценка на получените резултати (Hyndman, R.; Athanasopoulos, G., 2018), (O'Neil, C.; Schutt, R., 2013). Алгоритъмът е итеративен и отделни етапите може да се изпълняват и припокриват многократно във времето (фиг. 1).

Събирането на данни често е свързано с предварителни проучвания на предметната област, чрез които се придобива допълнителна информация, свързана с поставената задача. На този етап се формира представа за възможните фактори, влияещи върху прогнозираните величини.

Обединението и синхронизирането на данни по време, местоположение, сезони или други критерии, е неотменна дейност при използване на множество източници на данни за различни фактори.

Анализът и обработката на данни включват дейности по **проверка и изчистване на некоректни входни данни; преобразуване на данните в подходящ за моделиране формат; графични представяния на данните**, чрез които да се открият тенденции, периодичност, сезонност и др. Това предполага използването на разнообразни методи за анализ и последващо прогнозиране върху формираните сегменти.

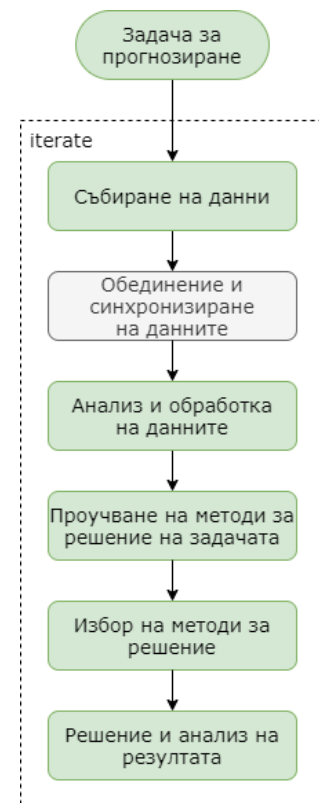
В етапа на **проучване на методи за решение на задачата за прогнозиране** се разглеждат различни съществуващи методи и алгоритми, или се създават собствени. Като методи за прогнозиране може да се ползват както стандартни статистически подходи, така и методи на изкуствения интелект. Броят на методите и употребата им може да зависи от: изискванията на конкретната задача; от фактори, свързани със средата; изпълнителите и др. Важна част от този етап е определянето на **показатели за оценка на ефективността на методите за прогнозиране**. Оценка на ефективността може да включва различни параметри, зависещи от обема данни, технически възможности на компютърните системи, цена, бързодействие и др.

При последните етапи се **избират** един или няколко от перспективните **модели за прогнозиране** и се прилагат за **решението на задачата**. След оценяването на резултатите, отделни етапи може да бъдат повтаряни многократно, с цел постигане на по-добри резултати.

Структурата на **дисертационния труд** следва описаните етапи за провеждане на научното изследване и се състои от **увод, пет глави и заключение, списък на авторските публикации по темата, декларация за оригиналност, списък на използваната литература и две приложения**, съдържащи резултати от извършените експерименти и част от MatLab-скриптовете на системата.

В **първа глава** на дисертацията е разгледана **структурата на Националната Електроенергийна система (НЕЕС) на България** и са посочени най-важните **компоненти**, осигуряващи нейното ефективно управление и **определящи необходимостта от ефективно прогнозиране на електропотреблението**. Определени са следните **основни фактори, влияещи върху потреблението на електрическа енергия**: Брутен вътрешен продукт; Енергийна интензивност; Численост на населението; Доходи на населението; Цена на електроенергията; Очаквани температури за съответния период; Енергийна ефективност; Електропотребление през предходен период. Направено е **проучване на научната литература за съществуващите методи и модели за прогнозиране на електропотреблението**.

Във **втора глава** са представени изследвания на зависимостите между отделните фактори и електропотреблението чрез използване на **корелационен и регресионен анализ, числени**



Фиг. 1. Основни етапи в процеса на прогнозиране

методи за интерполация и екстраполация. Разгледани са и методи за прогнозиране на факторите и електропотреблението, представени като **времеви редове**. Представени и реализирани с MatLab скрипт са **алгоритми за избор на най-ефективни модели за прогнозиране**, изградени върху съответните статистически и числени методи.

В трета глава от дисертацията са представени основните **теоретични концепции, стоящи зад идеята за създаване на ИНМ**. Разгледани са **възможностите на MatLab за изграждане на ИНМ**. **Изградени са ИНМ** за прогнозиране както на факторите, така на електропотреблението, разглеждани като времеви редове. Създадени са и ИНМ за прогнозиране на електропотреблението, разглеждано във връзката му с отделни или групи от фактори. **Резултатите от прогнозирането с ИНМ са сравнени с тези, получени с помощта на статистически и числени методи, описани в глава 2**. Предложен е итеративен **алгоритъм за автоматизирано търсене на оптимална ИНМ**.

В четвърта глава са описани **проектирането и реализацията на НКС за прогнозиране**, както и начините за интеграцията на вече изградените алгоритми за прогнозиране с числени методи и изкуствени невронни мрежи. Представени са получените от НКС **резултати за прогнозиране на всеки един от факторите, както и за електропотреблението в НЕЕС като цяло**. Проведени са и **допълнителни експерименти за прогнозиране на други величини в енергетиката**, които показват използваемостта на системата при решаване на разнообразни задачи за прогнозиране.

В пета глава са представени **резултатите от задача**, възникнала по време на дисертационното изследване - **за определяне на оптималния брой неврони в невронни мрежи**, използвайки матрица на Якоби при методите за обучение. Предложени са **формули за определяне на горни граници за необходимия брой неврони в невронна мрежа** с един или повече скрити слоеве.

В заключението е направен кратък преглед на поставените **проблеми и получените в резултат на изследването решения**. Посочени са **ползите от създадената НКС и са очертани насоки за бъдещото ѝ развитие**. Представени са основните **научни, научно-приложни и приложни приноси**.

В резултат от проведеното изследване:

- **проектирана и реализирана е НКС**, която може да бъде използвана за **автоматизирано прогнозиране**, не само на електропотреблението, но и на други величини.
- **проектирани и реализирани са алгоритми (в MatLab) за:**
 - намиране на най-ефективния модел на линейна регресия;
 - най-ефективно прогнозиране чрез екстраполация;
 - най-ефективно прогнозиране чрез времеви редове;
 - автоматизирано конструиране на оптимална ИНМ за прогнозиране и др.
- **предложени са формули за определяне на горни граници за необходимия брой неврони в невронна мрежа** с един или повече скрити слоеве, използвайки матрица на Якоби при методите за обучение.

Списъкът на използваната литература съдържа 119 източника, от които 30 на кирилица и 89 на латиница.

По темата на дисертацията има **6 публикации, от които 5 са индексирани в SCOPUS и/или WebOfScience**. Три от публикациите са в списания, и 3 – в сборници на научни конференции.

Резултатите са **докладвани на 3 конференция и 3 научни семинара, и са представяни в 3 научно-изследователски проекта**.

Във връзка с проучванията по темата на дисертационния труд са **разработени учебителни материали за студенти, за две избираеми дисциплини:**

- **Основи на невронните мрежи;**
- **Скриптово програмиране на невронни мрежи в Матлаб.**

В периода 2019-2021 г. двете избираеми дисциплини са проведени по два пъти – със студенти в редовна форма на обучение във Факултета по математика и информатика на Пловдивския университет „Паисий Хилендарски“.

Благодарности

Изказвам благодарностите си на научния ми ръководител доц. д-р Емил Хаджиколев, както и на доц. Станка Хаджиколева за помощта, подкрепата, идеите, насоките и препоръките при провеждане на дисертационното изследване. Благодаря за възможността да участвам в научноизследователски и образователни проекти, осигуряващи възможност за популяризирането на получените резултати.

Благодарности към доц. д-р Маргарита Терзийска за оказаното доверие при включването ми в екипа, провеждащ упражнения по статистика в УХТ-Пловдив, което ми позволи да открия допълнителни идеи при статистическите проучвания и анализ на информацията в дисертационното изследване.

Изказвам благодарности и към Електроенергийния системен оператор на България, в лицето на Мрежови експлоатационен район – Пловдив, за съдействието и предоставянето на реални данни, послужили за експериментална проверка на невро-кибернетичната система.


Благодаря на членовете на катедрата за тяхната подкрепа и препоръки.

Глава I. Прогнозиране на електропотреблението. Състояние на научните изследвания

Изследванията в тази глава са насочени към определяне на основните фактори, влияещи върху електропотреблението, преглед на състоянието на научните изследвания в областта и определяне на основните задачи в научното изследване. За целта **е разгледана структурата на Националната Електроенергийна система (НЕЕС) на България и компонентите, осигуряващи ефективното управление на НЕЕС**, които са основна предпоставка за необходимостта от правилното прогнозиране на електропотреблението. Представени са **основните фактори, влияещи върху потреблението на електрическа енергия**. Определени са **основните задачи по изграждане на НКС за прогнозиране на потреблението на електрическа енергия в НЕЕС на България**.

Структура на националната енергийна система

Националната електроенергийна система (НЕЕС) в най-общ план (фиг. 2) може да бъде разглеждана като **съвкупност от: мощности за производство на електрическа енергия; преносна мрежа**, осигуряваща доставката ѝ, при това в съответствие с приетите стандарти за качество; **дистрибутираща разпределителна система**; и крайното звено – **потребителите**.



Фиг. 2. Обща схема на Националната енергийна система

Компоненти на ефективното управление на НЕЕС

Като се абстрахираме от детайлите в структурата на НЕЕС, за правилното и ефективното ѝ функциониране, задължително трябва да се обърне внимание на следните фактори:

- 1) Състояние и управление на отделните компоненти на НЕЕС;
- 2) Точно прогнозиране на загубите в звената на ЕЕС;
- 3) Прецизно изчисление на електроенергийния баланс;
- 4) Прогнозиране на потреблението на електрическата енергия.

Фактори, влияещи върху потреблението на електрическата енергия

Успешното решаване на поставената задача е непосредствено свързано с правилната преценка на влияещите върху потреблението фактори. Това са макроикономически и демографски показатели, социални параметри, климатични условия и други. В настоящата работа са изследвани няколко фактора, оказващи влияние върху електропотреблението.

- 1) Брутен вътрешен продукт;
- 2) Енергийна интензивност;
- 3) Численост на населението;
- 4) Доходи на населението;
- 5) Цена на електроенергията;
- 6) Очаквани температури за съответния период;
- 7) Енергийна ефективност;
- 8) Електропотреблението през предходен период.

Състояние на научните изследвания

Без значение дали става въпрос за дългосрочни, средносрочни или краткосрочни прогнози, предвиждането на консумацията на електроенергия има основна роля както за планирането на инвестиции, въвеждането на нови мощности или извеждането на ненужни такива, така и за оценка на поведението на цялата икономическа система. Ефективното моделиране на потреблението на електроенергия става жизненоважна задача, чието решение има за цел да се избегнат скъпи грешки в неразумни инвестиции, изключване на важни мощности, неправилно предвидени ремонти дейности или недалновидност в износа или вноса. Ето защо, не бива да се

учудваме, че в литературата по въпроса съществуват множество предложени варианти за справяне с проблемите на прогнозирането.

Официални проучвания в насока енергийно развитие на България, фактори, влияещи на електропотреблението и подходи за прогнозиране на потреблението и факторите са правени от БАН и Risk Management Lab. Традиционните методи, като корелационен и регресионен анализ може да се видят използвани и в двете проучвания (БАН-стратегия, 2017), (Risk Management Lab, 2014).

В (БАН-стратегия, 2017) е направен основен и задълбочен анализ на влиянието на отделните фактори, влияещи върху електропотреблението. Разгледани са брутния вътрешен продукт на страната, брутната добавена стойност по сектори на икономиката, числеността на населението, броя на заетите лица, доходите, цените, промяната на температурите до 2040 г., според прогнозите на НИМХ и др. Направени са прогнози въз основа на три различни сценария според различни очаквания за промени на факторите.

Екипът на (Risk Management Lab, 2014) създава математико-статистически модели за прогнозиране на електроенергийния баланс (включително като елемент от него и прогнозиране на потреблението на електроенергия). В изследването се разглеждат специфични фактори по отношение на електропотреблението от домакинствата и индустрията.

Поради голямото обществено и икономическо значение на прогнозирането на потреблението на електроенергия, през последните няколко десетилетия много учени са предложили различни видове прогнозни модели за решаване на проблема. **Методите за прогнозиране на електропотреблението може да бъдат определени в няколко категории:**

- **статистически модели за анализ – корелационни методи и регресионни модели** (БАН-стратегия, 2017), (Risk Management Lab, 2014), (Mohamed, Z.; Bodger, P., 2005);
- **времеви редове** (Lee, Y.; Gaik, T.; Yee, Ch., 2018), (Sun, T.; Zhang, T.; Teng, Y.; Chen, Z.; Fang, J., 2019);
- **сиви системи за прогнозиране на Грейнджър** (Ding, S.; Hipel, K.; Dang, Y., 2018) , (Lee, Y. S.; Tong, L.T., 2011), (Huang, Y.; Wang, C.; Dang, H.; Lai, S., 2016);
- **невронни мрежи** (Chung, Y., 2017), (Chernykh, I.; Chechushkov, D.; Panikovskaya, T., 2014), (Khosravani, H.; Castilla, M.; Berenguel, M.; Ruano, A; Ferreira, P., 2016), (Yoo, S.; Myriam, H. A., 2018), (Hu, Yi-Chung, 2017),(Jahn, M., 2018);
- **комбинация от различни похвати** (Karatasou, S.; Santamouris, M.; Geros, V., 2008), (Cervená, M.; Schneider, M., 2014) и др.

Всеки от разгледаните подходи има своите предимства и недостатъци при различни конкретни задачи и ситуации. Това показва, че планираното създаване на автоматизирана система за прогнозиране, в която може да се изпълняват и сравняват множество модели за прогнозиране, би могло да донесе множество ползи при прогнозиране не само на електропотреблението, но и на други величини.

Глава II. Статистически и числени методи за прогнозиране

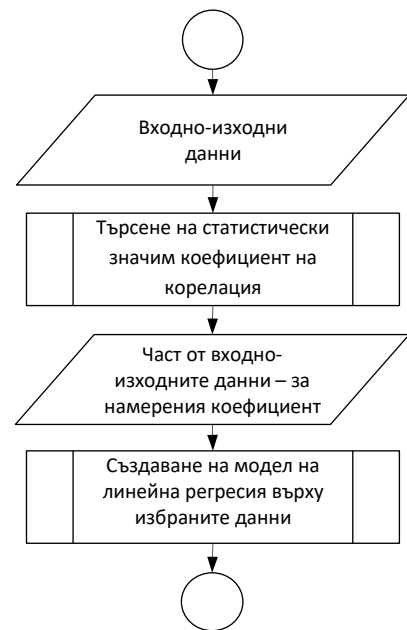
В настоящата част са приложени стандартни статистически и числени методи, моделиращи връзките между вече установените фактори и електропотреблението. Успоредно с това са

изградени функционалности в MatLab, които биха могли да се използват при изграждането на цялостната система за прогнозиране.

Корелационен и регресионен анализ

При **корелационния анализ** се определя степента на зависимост между стойностите на две променливи величини. В нашия случай, изследваме какви са зависимостите за различни двойки величини „фактор-електропотребление“ като използваме стойности за тях, изчислени в определени интервали от време – годишни, дневни, часови или др. За оценка на силата на връзката между факторите и консумацията на електроенергия е избран корелационния коефициент на Пиърсън R (Съйкова, И., 1981).

За да създадем ефективен модела на линейна регресия (фиг. 3), първо се опитваме в данните за независимите и зависимите променливи да намерим статистически значим коефициент на корелация R . Изследвайки последователно различни периоди, намираме най подходящия коефициент на корелация. След това, създаваме модела на линейна регресия върху определената част от данните.



Фиг. 3. Алгоритъм за намиране на най-ефективния модел на линейна регресия

Интерполация и екстраполация

Числените методи, в лицето на нелинейни интерполационни или екстраполационни процедури подобряват възможностите за прогнозиране.

Интерполация използваме, когато при множество входни данни $X_i = \{x_{i1}, x_{i2}, \dots, x_{in}\}$ за фактора $X_i, i \in N$, търсим прогнозна стойност на целевата величина (електропотреблението) съответна на факторна стойност намираща се в интервала от минималната и максималната стойност на X_i , т.е. $x_{i(n+1)} \in (\min X_i, \max X_i)$. Един стандартен подход при интерполация е използването на полином на Лагранж (Гочева-Илиева, С., 2013), за което е реализирана съответната функционалност в MatLab и е приложена при прогнозиране на електропотреблението като функция на фактора температура.

Повечето фактори, влияещи на електропотреблението, следват общ възходящ или низходящ тренд. Това налага при прогнозиране на електропотребление за даден период да се използва стойност на фактора извън извадката и съответно прилагане на методи за екстраполация.



Фиг. 4. Алгоритъм за най-ефективно прогнозиране чрез екстраполация

Идеята на предложеният и реализирани алгоритъм за прогнозиране чрез екстраполация (фиг. 4) е да се използват няколко метода за екстраполация – линеен, кубичен, сплайн – след което да се сравнят и избере този с най-малка грешка при тестването с предвидените за него данни.

За оценка на ефективността и като критерии за сравнение с получените от невронните мрежи резултати, са използвани (при 4-годишни периоди на прогнозиране) минималните стойности на следните грешки: Средна абсолютна грешка (хил. тона н.е.); Средна процентна абсолютна грешка (%); Средна квадратична грешка (хил. тона н.е.).

Представените в дисертацията резултати показват, че при екстраполация, макар и приемлива като метод за прогнозен период, близък до извадката, грешките стават големи, когато точките се отдалечават от дефиниционната област на факторите.

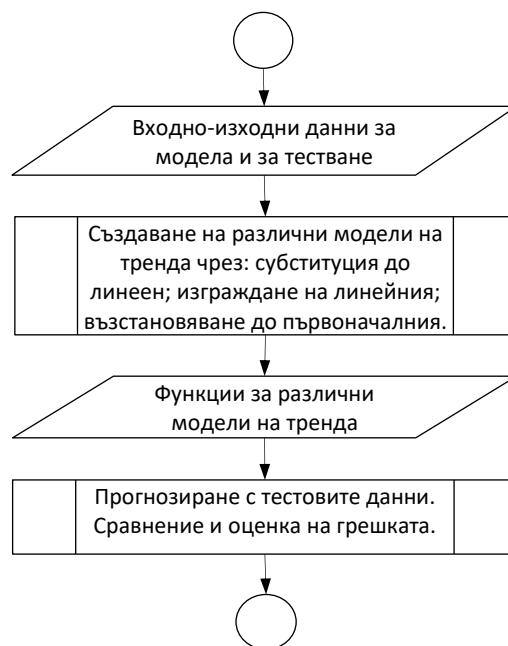
Времени редове

Факторите, влияещи върху електропотреблението се променят с времето. Тези промени могат да бъдат описани като функция на съответния фактор от момента на неговото измерване: $y = y(t)$. При работа с временни редове (ВР) се използват класически модели (Дамгалиев, Д.; Теллалян, Ж., 2006), (Гочева-Илиева, С., 2014).

Трендът е най-използваното средство за прогнозиране на бъдещи стойности на един ВР. За да установим какъв е модела на тренда на ВР, изследваме различни модели: линеен, квадратичен, кубичен, хиперболичен, дробно-рационален, логаритмичен, експоненциален, степенен, комбиниран (табл. 1) и ги сравняваме (фиг. 5), за да изберем най-ефективния от тях.

Таблица 1. Използвани модели на тренда

Тип на тренда	Математически модел
Линеен	$\hat{y} = \beta_1 + \beta_2 t$
Квадратичен	$\hat{y} = \beta_1 + \beta_2 t + \beta_3 t^2$
Кубичен	$\hat{y} = \beta_1 + \beta_2 t + \beta_3 t^2 + \beta_4 t^3$
Хиперболичен	$\hat{y} = \beta_1 + \frac{\beta_2}{t}, t \neq 0$
Дробно-рационален	$\hat{y} = \frac{t}{\beta_1 + \beta_2 t}, t \neq -\frac{\beta_1}{\beta_2}$
Логаритмичен	$\hat{y} = \beta_1 + \beta_2 \ln(t)$
Експоненциален	$\hat{y} = \beta_1 e^{\beta_2 t}$
Степенен	$\hat{y} = \beta_1 t^{\beta_2}$
Комбиниран	$\hat{y} = \frac{t}{\beta_1 + \beta_2 e^{-t}}, t \neq \ln \frac{\beta_1}{\beta_2}$



Фиг. 5. Алгоритъм за най-ефективно прогнозиране чрез временни редове

Идеята, която е използвана за изграждането на нелинейни модели на тренда е свеждането им чрез субституция до линеен. След това, се изчислява линейния модел по метода на най-малките квадрати и се извършва обратната субституция до изграждане на първоначално търсения нелинеен модел.

От направените експерименти се установи, че **прогнозирането чрез времеви редове има своите предимства при краткосрочни прогнози за величини, които имат ясно откроявани трендове. При прогнозиране на величините за по-дълъг период от време, се забелязва нарастване на грешките с отдалечаване от границите на стойностите в извадката.**

Изводи

Корелационният анализ чрез диаграмите на разсейването и корелационните коефициенти и може да ни даде основна представа за наличието и липсата, както и за силата на връзката между две величини.

Не може да се каже, че корелационният анализ винаги носи в себе си информация за съществуваща причинно-следствена връзка между две явления.

При статистически значими стойности на корелационния коефициент е подходящо създаването на прогнозиращи модели, базирани на линейна регресия. Не винаги обаче зависимостите между величините са линейни и в такива случаи линейната регресия е неефективна.

Методът на интерполация се оказва сравнително успешен в ситуации, при които прогнозата се прави върху данни, които са в диапазона на използваните за изграждане на модела данни.

В повечето случаи, обаче, данните за прогнозиране, са извън извадката за създаване на модела и в такива случаи е подходящо да се използват методите за екстраполация.

Прогнозирането чрез времеви редове има своите предимства при краткосрочни прогнози за величини, които имат ясно откроявани трендове.


Глава III. Използване на изкуствени невронни мрежи за прогнозиране

В третия етап от работата са изследвани отделни фактори, влияещи върху потреблението на електрическа енергия в НЕЕС на България с помощта на ИНМ.

Изкуствени неврони и връзката им с биологичния първообраз

Човешкият мозък съдържа около 25 милиарда нервни клетки – неврони, които общуват помежду си по различни (химически, електрически или смесени) начини чрез своите синапси (Дудел, Дж.; Рюегг, И.; Шмидт, Р.; Яниг, В., 1985).

Основавайки се на биологичните особености на нервната клетка, можем да обобщим, че основната задача на неврона е **приемането**,



Фиг. 6. Схема на изкуствен неврон

обработването и предаването на информация, чиято степен на значимост е образувала биоелектрически потенциал надхвърлил прага на клетката.

Спазвайки еволюционно създадения модел, структурата на изкуствения неврон може да бъде представена схематично чрез фиг. 6. В нея:

- $\vec{X}(x_1, x_2, \dots, x_n)$ е вектора от входни стимули;
- $\vec{W}(w_1, w_2, \dots, w_n)$ е тегловия вектор;
- b – праг на неврона;
- S – функция моделираща сумирането на входните стимули;
- g – активираща/трансферна функция, обособяваща изходния сигнал по аксона.

Прагът със стойност b на изкуствения неврон може да се разглежда като допълнителен стимул със стойност 1, който въздейства на неврона с тегло $w=b$.

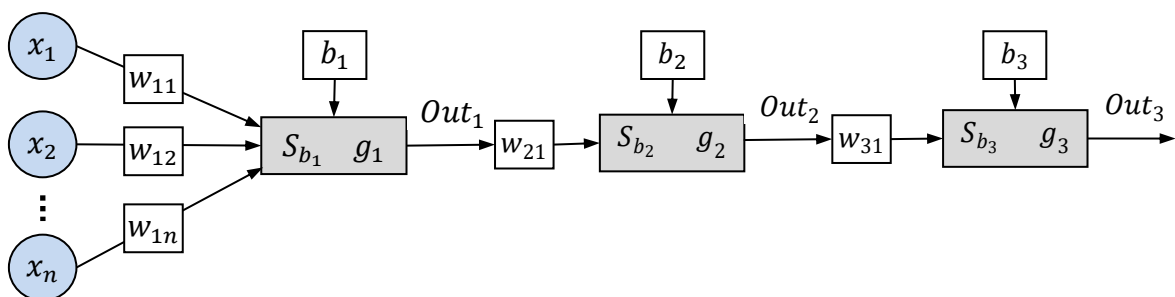
В последващата обработка на информацията от страна на неврона, образуваният общ сигнал S се подлага на действието на трансферната функция g , чрез която се изработва краен изходен сигнал, или предаващ се към следващия елемент в мрежата междинен резултат:

$$Output = g \left(\sum_{i=0}^n (x_i w_i) \right).$$

Функциите, активиращи неврона, могат да бъдат от различен тип. Наричат се активиращи функции или трансферни функции. Изборът на активираща функция се определя от задачата на мрежата или желаната точност (Кирова, Т., 1995) (Мишева, М.; Шишков, Д., 1995). Често използвани са: линейна; сигмоидна; хиперболичен тангенс; прагова функция; функция на Гаус.

Искусствени невронни мрежи

ИНМ са системи, състоящи се от множество свързани помежду си неврони. Всеки отделен неврон получава входни сигнали от средата и генерира изходен резултат, който може да послужи като входен за един или повече други неврони. Решавайки една задача, сигналите може да преминават еднократно или многократно през едни и същи неврони, в зависимост от начина на работа на мрежата.



Фиг. 7. Примерна невро-кибернетична система от три неврона

Невронната система на фиг. 7 се състои три неврона, за които изходния резултат на първия е входен сигнал за втория, а неговият изходен сигнал е входен за третия. Към първия неврон постъпват данните от външната среда за веригата и затова се нарича „входен“. От последния неврон се разпространява изходния сигнал за цялата структура и затова е прието да се нарича

„изходен“. Докато входният и изходният неврон са видими за външния наблюдател, всичко което се случва между тях често остава скрито, невидимо и недостъпно за външния свят. Това е причината в литературата този междинният неврон да се нарича „скрит“. (Мишева, М.; Шишков, Д., 1995), (Miikkulainen, R., 2011).

Обикновено, създаваните невронните структури не са линейни, като вече разгледаните, а много по сложни. Съвкупността от всички входни неврони се нарича **входен слой**. Множеството от всички скрити неврони се нарича **скрит слой**, а това от изходните неврони – **изходен слой** на тази система.

За да започне работа една ИНМ, също както биологичните невронни системи, които не се раждат програмирани със знание и способности, тя трябва да бъде предварително обучена. **Според вида на обучението** можем да различим следните основни направления: **асоциативно обучение и самоорганизация**.

Асоциативно обучение, е известно още като **обучение с учител**. При този тип обучение **мрежата се учи, като ѝ се предоставят освен входните данни и съответстващ им изходен образец. При обучението теглата на мрежата се уточняват, като се използва разликата между стойностите от изходните неврони при зададените входни образци** (Кирова, Т., 1995).

Самоорганизация, или **обучение без учител. При този метод изходните неврони се обучават да отговарят на класове от входни образци. Тази идея предполага, че НМ открива най-характерните черти на входната популация.** За разлика от обучението с учител, в случая не съществува множество от категории, с които да се съпоставят входните данни и по-скоро мрежата сама трябва да изработи собствено представяне на входните стимули (Кирова, Т., 1995).

Самото обучение на невронните мрежи е изградено на принципи за нагласяване на теглата на връзките между отделните неврони съгласно някакво модифицирано правило, което общо взето следва модели базирани на идеите на Хеб. Съществуват много и най-различни по характер такива обучаващи методи (табл. 2). При търсене на подходяща НМ с разработения от нас модел, търсенето преминава през всеки от тях.

Таблица 2. Използвани в изследването методи за обучение

Levenberg-Marquardt
Bayesian Regularization
Scaled Conjugate Gradient
BFGS Quasi-Newton
Resilient Backpropagation
Conjugate Gradient with Powell/Beale Restarts
Fletcher-Powell Conjugate Gradient
Polak-Ribière Conjugate Gradient
One Step Secant
Variable Learning Rate Backpropagation

Работа с ИНМ в MatLab

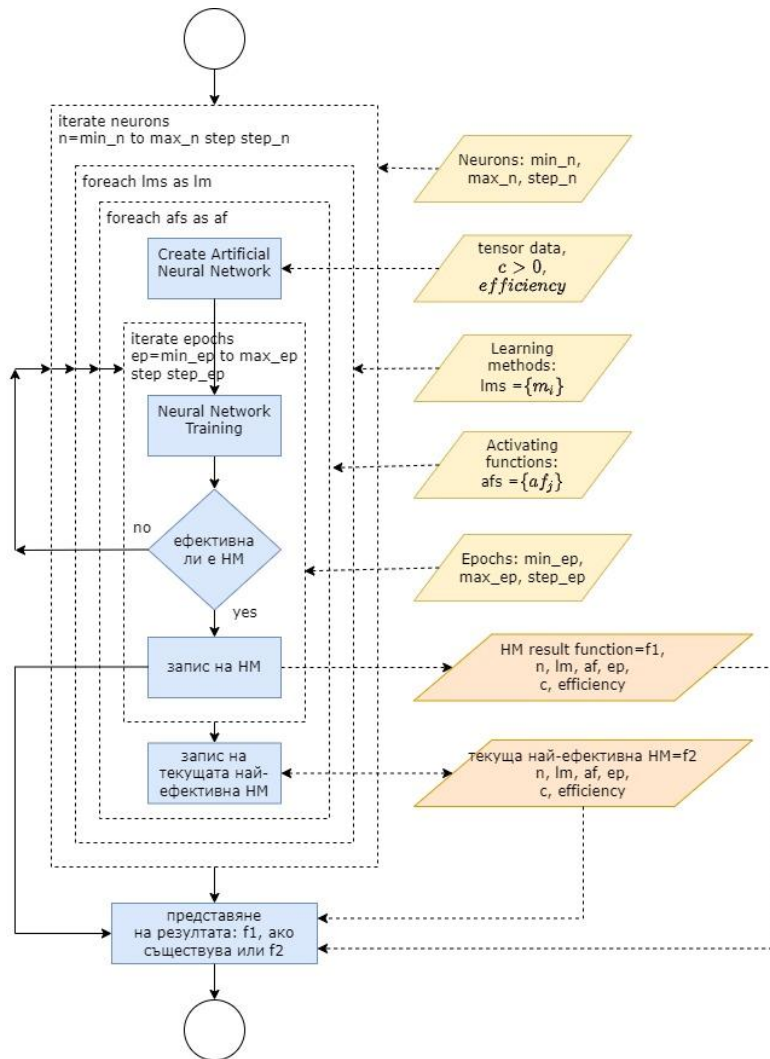
При първоначалните експерименти за прогнозиране с ИНМ, са използвани графични инструменти на MatLab, а на следващ етап са използвани скриптовите възможности на средата при изграждане на модулите на софтуерния прототип на системата за прогнозиране.

За решаването на една задача могат да бъдат построени множество различни ИНМ, с различен брой неврони в скрития слой, с по-голяма или по-малка грешка и различни резултатни функции, които имат близко поведение при използваните входно-изходни образци.

Грешката не винаги е показател за сложността на мрежата. По-малкият брой на невроните предполага по-бързо и лесно обучение на мрежата и впоследствие – по-бърза работа.

Алгоритъм, предоставящ възможности за автоматизирано конструиране на множество невронни мрежи би подпомогнал избора на оптимално решение. Един експериментиран от нас

подход за създаването на оптимална ИНМ е итерирането върху различни параметри, необходими за създаване на ИНМ: брой на невроните в скрития слой, активиращи/трансферни функции, алгоритми за обучение и брой на епохите при обучението. При него, последователно се променят параметрите за създаване на ИНМ и се изследва ефективността на текущата мрежа. Първата мрежа, която удовлетворява заложените от потребителя изисквания се приема за оптимална. Поради това, важна част от алгоритъма е начина на изменение на итерационните параметри. Тъй като създаването и обучението на всяка ИНМ изисква определени компютърни ресурси и време, итеративният подход е удачно да се използва върху еднопроцесорни машини само при задачи, при които се очаква намирането на подходящата мрежа да е с относително малък брой итерации.



Фиг. 8. Итеративен алгоритъм за конструиране на оптимална ИНМ за прогнозиране

Итеративният алгоритъмът за автоматизирано конструиране на ИНМ (фиг. 8) има следните основни стъпки:

- **Подготовка на входните данни:**
 - **Tensor data** – входни данни за факторите, които обикновено са във вид на едномерен $\{x_i\}_{i=1..k}$ – или двумерен масив $\{x_{i,j}\}_{i=1..k}^{j=1..n_i}$.
 - **Брой на прогнозните резултати** – c – който е 1 при едноточкови прогнози или по-голямо цяло число при многоточкови прогнози.
 - **Желана ефективност** – *efficiency* – на обучената невронна мрежа.
- **Подготовка на параметрите, върху които се итерира:**
 - **Списък с методи за обучение** $lms = \{m_i\}$, където i се изменя от 1 до броя на методите. В зависимост от задачата, с цел по-бързо достигане до търсения резултат е възможно методите да се подредят в списъка според очакваната ефективност, а някои дори може да се изключат, ако се прецени, че не са подходящи.

- **Списък с активиращи функции** $afs = \{af_j\}$, където j се изменя от 1 до броя на функциите. Тук също функциите могат да се подредят по преценка за уместността на употребата им в конкретната задача.
 - **Минимален и максимален брой на невроните** – min_n и max_n , както и **стъпка, с която се променят невроните** – $step_n$. **Текущият брой неврони** означаваме с n . За по-елементарни задачи е възможно броят на невроните да започва от 1 ($min_n = 1$) и стъпката, с която се увеличава броят им, също да е 1. Максималният брой ограничава възможните итерации, свързани с броя на невроните.
 - **Епохите** $epochs$ се променят от min_ep до max_ep със стъпка $step_ep$. Стойности, с които сме експериментирали са $min_ep = 1000, max_ep = 5000, step_ep = 1000$, като обикновено са достатъчни 3-4 итерации, за да се прецени дали промяната на епохите оказва влияние върху ефективността на обучената мрежа.
 - **Итерирайки върху броя на невроните, методите за обучение и активиращите функции, се създава невронна мрежа с текущите им стойности – наредената тройка (n, lm, af) – и входните данни.** Въпрос на преценка за конкретната задача е влагането на циклите, която определя последователността на промяна на параметрите. При провежданите експерименти, сме избрали в най-външния цикъл да се увеличава броя на невроните, тъй като желаем да намерим мрежа с най-малък брой неврони. Методите за обучение и активиращите функции се сменят във вътрешните цикли.
- След създаване на текущата невронна мрежа тя се обучава, валидира и тества.
 - Сравнява се желаната ефективност с ефективността на текущата мрежа, след което:
 - ако мрежата удовлетворява условието, данните за нея се записват и изпълнението на задачата приключва;
 - в противен случай се правят опити за повишаване на ефективността на невронната мрежа чрез повишаване на броя на епохите за обучение. Информацията за намерената най-ефективна мрежа (с най-малка грешка) се записва, като тя може да е текущата или да е получена при предходна итерация.
 - Крайният резултат от работата на алгоритъма е обучена ИНМ, притежаваща възможно най-близка до указаната ефективност, а също така и параметри за архитектурата и обучението ѝ – ефективност, брой неврони n , метод за обучение lm , активираща функция af , и епохи ep .

Използването на метода на „грубата сила“, с обхождането на всички възможни стойности на итерационните параметри и намиране на мрежата с най-високи показатели на съотношението „брой неврони-ефективност“ не е най-рационалният подход. Проследяването на промените в указаното съотношение може да доведе до създаването на евристични варианти на алгоритъма, чрез автоматизирано изменение на реда на промяна на итерационните параметри.

Наличието на достатъчно изчислителни мощности предразполага към използването на различни паралелни алгоритми за подобно автоматизирано търсене на оптимална НМ, при които например може в паралелни процеси да се стартират всички комбинации от методи за обучение и активиращи функции.

Прогнозиране на факторите и електропотреблението с ИНМ

В тази част са представени сравненията между прогнозни резултати, получени с числени методи (описани в глава 2) и създадените ИНМ.

При сравнение на най-ефективните методи за факторите се вижда ясно превъзходството на ИНМ (табл. 3).

Таблица 3. Сравнение на прогнозните резултати от числените методи и ИНМ, за факторите

Фактор	Метод на прогнозиране с времеви ред	Абсолютна грешка	ИНМ	Абсолютна грешка
Брутен вътрешен продукт	Апроксимация с линеен тренд	316,41 млн. лева	Net_BVP	20,6075 млн. лева
Енергийна интензивност на икономиката	Апроксимация с логаритмичен тренд	4, 37168233e -05 лв./т.н.е.	Net_Int	3,5291e-06 лв./т.н.е.
Численост на населението	Апроксимация с линеен тренд	16357,6043956019 души	Net_Nas	1835,687552735210 души
Среден годишен доход	Апроксимация с линеен тренд	105,038461538460 лева	Net_Sgd	19,557134817202495 лева
Цена на ел.енергия за домакинствата	Апроксимация с квадратичен тренд	0,254166666666670 стотинки/кв.ч.	Net_Cd	0,028291881850667 стотинки/кв.ч.
Цена на ел.енергия за индустрията	Апроксимация с хиперболичен тренд	0,732397329769455 стотинки/кв.ч.	Net_Ci	0,089974790851567 стотинки/кв.ч.

Аналогичен е резултата от сравнението за видовете потребление (табл. 4).

Таблица 4. Сравнение на прогнозните резултати от числените методи и ИНМ, за видовете електропотребление

Потребление	Метод на прогнозиране с времеви ред	Абсолютна грешка (хил. т.н.е.)	ИНМ	Абсолютна грешка (хил. т.н.е.)
Общо крайно потребление в НЕЕС	Апроксимация с кубичен тип на тренда	199,3338235294	Net_Nees	7.1966
Потребление на електроенергия в индустрията, публичния сектор и услугите	Апроксимация с комбиниран тренд	111,1595323699	Net_Industry	41.4787
Потребление на електроенергия в домакинствата	Апроксимация с линеен тренд	24,466666666666	Net_Households	0.0374

При прогнозиране от вида „фактор-електропотребление“ или „два фактора-електропотребление“ също се установява, че **абсолютната грешка при прогнозиране с ИНМ е по-малка.**

Изводи

При едногодишното прогнозиране ИНМ са по-ефективни от използваните числени методи. В определени случаи ефективността им е с няколко порядъка по-висока от използваните времеви редове.

При дългосрочно прогнозиране – далеч от краищата на извадката – ИНМ показват само малки отклонения от последната изчислена стойност. **Това прави ИНМ несигурно средство за**

дългосрочно прогнозиране. В тези случаи по-правдоподобни заключения се предлагат от разглеждането на тренда на реда чрез стандартните подходи за прогнозиране със статистически и числени методи.

Една автоматизирана система за прогнозиране трябва да включва различни методи и подходи за прогнозиране – статистически методи, числени методи, ИНМ и др. Голямо предизвикателство при автоматизираното изследване на множество методи, е бързото намиране на оптимално решение. Част от тях са споменати при вече разглежданите алгоритми за автоматизация на прогнозирането – правилен избор на критерии за край на метода; подходи за избор на най-подходящи параметри при итерационни алгоритми и др.

Глава IV. Невро-кибернетична система за прогнозиране

В настоящата глава е представен процеса на проектиране и изграждането на цялостна автоматизирана НКС, с помощта на която биха могли да се прогнозира както бъдещото поведение на отделните фактори дефиниращи консумацията, така и самото електропотребление в НЕЕС.

В общия случай, решаването на всяка една задача за прогнозиране се извършва по сходен начин, който може да бъде сведен до няколко етапа – събиране и обработка на данни, проучване на методите за решение, решение, и анализ на получените резултати (Hyndman, R.; Athanadoroulos, G., 2018), (O'Neil, C.; Schutt, R., 2013) (фиг. 1 и фиг. 9). Отделните етапи може да се изпълняват многократно.

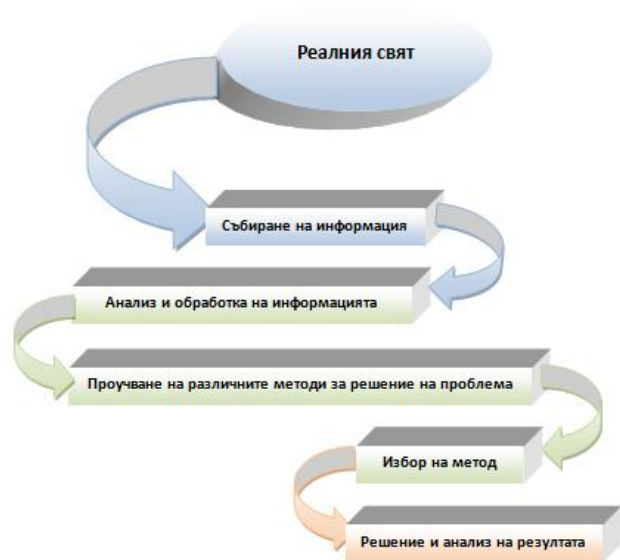
Проектиране на НКС

Автоматизирането на различни етапи и дейности от процеса на прогнозиране значително улеснява работата и намалява вероятността за допускане на грешки и неточности. Една такава система трябва да поддържа следните базови възможности:

- механизми за интегриране на различни методи за прогнозиране в системата,
- възможности за работа с различен брой фактори, и
- автоматизирано търсене и избор на ефективни методи за прогнозиране при решението на конкретна задача.

В предложения модел за автоматизирано търсене на ефективни методи за прогнозиране се използват два основни подхода:

- **complex forecasting**, приложим при многофакторно прогнозиране, при който се извършва предварително прогнозиране на отделните фактори, и
- **simple forecasting**, приложим в случаи, в които целевата величина се разглежда като времеви ред или поведението на факторите е известно.



Фиг. 9. Етапи в процеса на прогнозиране

Основният подход за работа в системата за прогнозиране чрез ИНМ, може да бъде представен формално по следния начин:

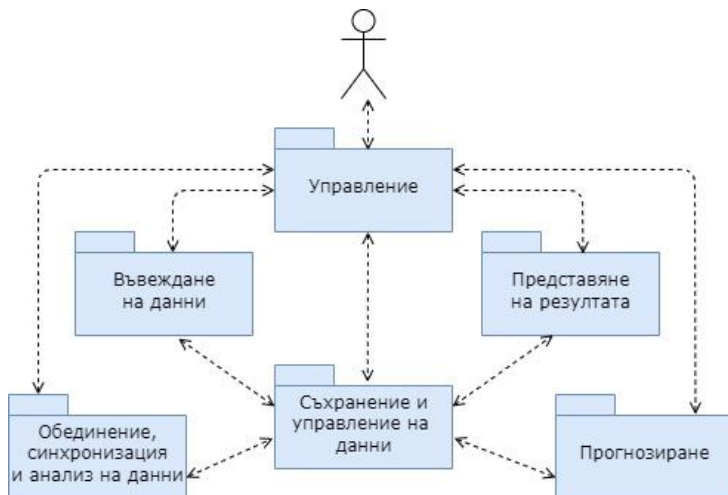
Нека е дадено събитието/величината $S = S(\vec{X}_1, \vec{X}_2, \dots, \vec{X}_k)$, чийто изход е определен от k въздействащи му фактори $\vec{X}_1, \vec{X}_2, \dots, \vec{X}_k$. Нека за всеки от факторите \vec{X}_i има предоставена извадка от стойности $\vec{X}_i: (x_{i,1}, x_{i,2}, \dots, x_{i,j_i}), i = 1, 2, \dots, k, j_i \in N$.

Основните стъпки, изпълнявани от системата при използването на complex forecasting са следните:

- 1) Автоматично търси и конструира ИНМ NN с входни вектори \vec{X}_i , апроксимираща S с минимална грешка E_{NN} ;
- 2) Въз основа на извадките $(x_{i,1}, x_{i,2}, \dots, x_{i,j_i})$ прогнозира бъдещето поведение на факторите \vec{X}_i с помощта на p на брой различни методи $\{m_t\}_{t=1..p}$;
- 3) За всеки един от факторите \vec{X}_i поотделно се извършва сравнение на ефективността на използваните прогнозни методи;
- 4) За прогнозна стойност на \vec{X}_i се избира прогнозата на съответния най-ефективен метод;
- 5) Чрез прогнозните стойности на факторите \vec{X}_i и метода M се осъществява прогноза за изхода на събитието.

За оценка на ефективността на методите за прогнозиране може да се използват различни критерии, като грешка при решението, цена, бързодействие, използвани компютърни ресурси, и др. В нашето изследване избираме да **наричаме метода M_1 по-ефективен от M_2 , ако притежава по-малка грешка при прогнозирането**, т.е. $E_{M_1} \leq E_{M_2}$. За стойности на грешката може да се ползват абсолютната грешка или средно-квадратичната грешка, получавани при прогнозиране върху n -мерен масив с данни.

При едноточкови прогнози (single point forecast), създадени върху $(n - 1)$ елемента от извадката, абсолютната грешка при прогнозиране на последния елемент е:



Фиг. 10. Основни модули и връзките между тях в системата за прогнозиране

$$AE = |Real_n - Forecast(n)|,$$

където

- $Real_n$ е реалната стойност на измерваната величина, а
- $Forecast(n)$ е прогнозната стойност, предложена от използвания метод.

При многоточкови прогнози за последните k елемента на масива с данни, средната абсолютна грешка се изчислява по формулата

$$MAE = \frac{1}{k} \sum_{i=n-k+1}^n |real_i - forecast(i)|, \text{ а}$$

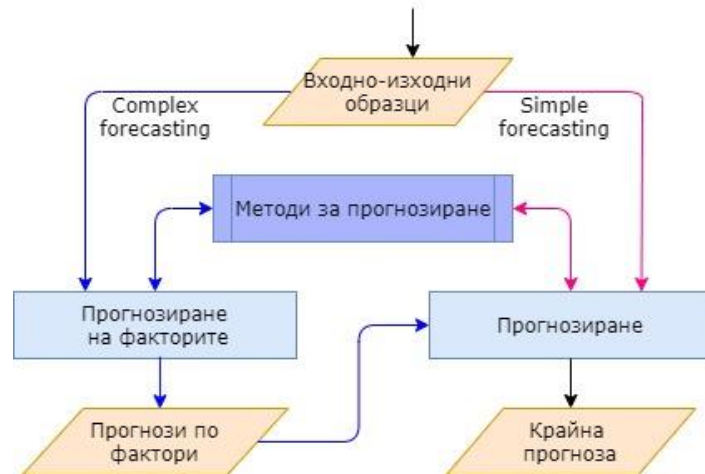
средно-квадратичната грешка е

$$MSE = \frac{1}{k} \sum_{i=n-k+1}^n [real_i - forecast(i)]^2.$$

Модулите в една софтуерна система за прогнозиране автоматизират част от основните дейности (фиг. 10) в процеса на прогнозиране. Потребителят на системата достъпва отделните модули чрез общ интерфейс, осигурен от **модула „Управление“**. Освен връзката с потребителя, той осигурява управление и контрол на останалите модули.

Модул „Въвеждане на данни“ подпомага потребителя при въвеждане на данни и първоначалното им класифициране.

Инструментите за обединение и синхронизация са полезни в случаите, в които се използват данни от различни източници. По избор на потребителя, чрез функции или параметри, се извършва преобразуване на данните в модел, подходящ за извършване на прогнози. Анализът на данните се подпомага от интегрирани в модула графични инструменти и стандартни статистически методи, предоставящи на потребителя възможност за допълнително класифициране и изчистване на некоректни данни, и подготовка на различни модели на данните.



Фиг. 11. Модул „Прогнозиране“

Модул „Прогнозиране“ (фиг. 11) представя възможност за избор на един или повече методи за прогнозиране, както и възможност за оценяване на най-ефективния метод. Важна възможност, която трябва да поддържа системата, е за лесна интеграция в модула на нови методи за прогнозиране и оценяване.

Модул „Представяне на резултата“ съдържа графични инструменти за визуализиране на получените резултати от най-ефективния метод, както и от всички останали използвани методи.

Модулът за съхранение и управление на данните предоставя достъп до различни видове данни, които могат да бъдат използвани при конфигуриране, обучение на методите за прогнозиране, и последващото им използване:

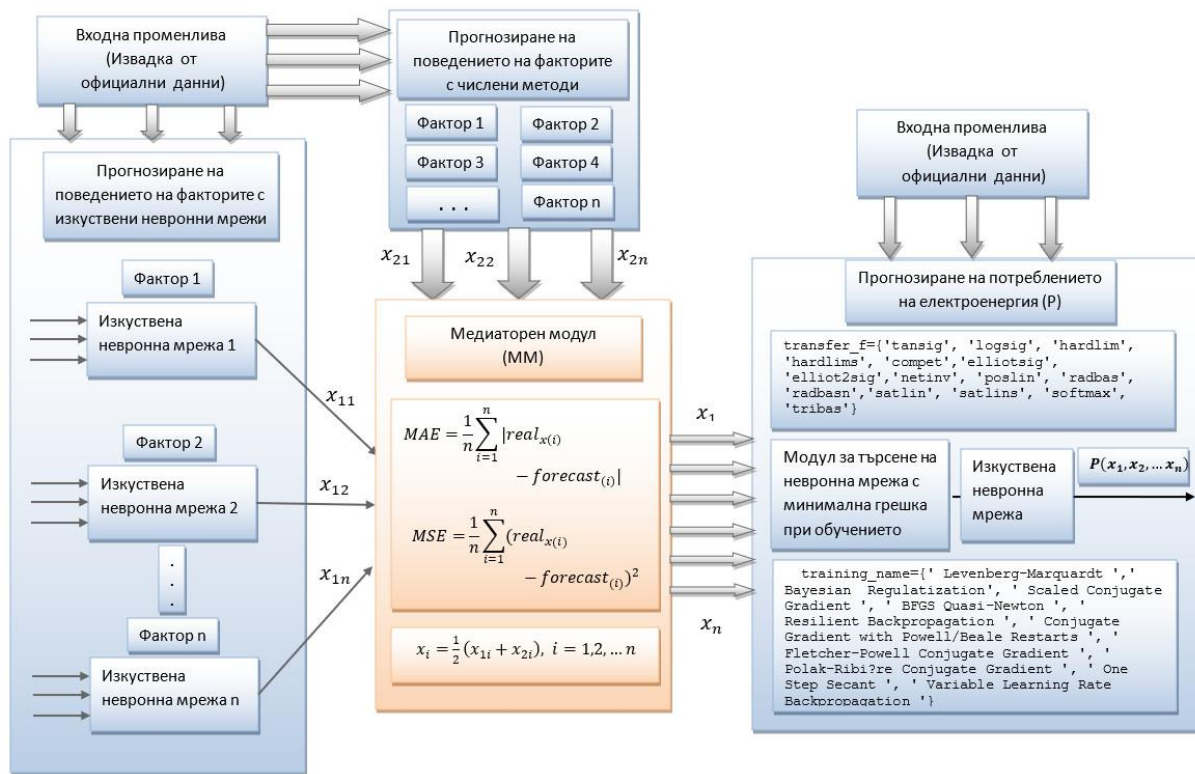
- първични входно-изходни данни и начални параметри;
- модели на данните, използвани от методите за предсказване;
- задавани от потребителите критерии за максимално допустима грешка;
- брой и вид на използваните методи;
- получени грешки при всеки един от методите;
- идентификатор на най-ефективния метод;
- резултати от задачи за прогнозиране, и др.

При разглеждане на методите за прогнозиране, в глави 2 и 3 са представени алгоритми за **търсене на оптимални или най-ефективни методи за прогнозиране**. За повечето от тях в процеса на изследването бяха изградени съответни функционалности, които могат да бъдат използвани при цялостната реализация на НКС. Цялостният алгоритъм за прогнозиране може да включва всички или най-подходящите от тях, в последователен или паралелен вариант.

Реализация на НКС

При реализация на прототипа на НКС за прогнозиране на електропотреблението са използвани разглежданите в предходните глави методи за прогнозиране чрез числени методи и ИНМ, които се оказаха най-подходящи при конкретната задача за прогнозиране на

електропотреблението. Предвидените при проектирането функционалности са реализирани чрез предлаганите от MatLab скриптові средства.



Фиг. 12. Схема на НКС за прогнозиране на електропотреблението

За въвеждането и съхранението на данните са използвани стандартни скриптові възможности на MatLab за работа с файлове. Логиката в модула за „Управление“ е свързана с управление на последователността на изпълнение на отделните функционалности:

- зареждане на входно-изходни данни;
- прогнозиране на факторите по различни методи;
- избор на най-ефективни методи за факторите;
- прогнозиране на факторите с избрания метод;
- прогнозиране на електропотреблението, чрез прогнозираните данни за факторите;
- представяне и запис на резултатите във файл.

Основната логика в процеса на прогнозиране на електропотреблението може да се представи чрез схемата на фиг. 12. НКС има 3 основни модула, разгледани по-подробно в дисертационния труд:

- 1) Модул за прогнозиране на факторите чрез числени методи и ИНМ;
- 2) Модул за прогнозиране на електропотреблението;
- 3) Медиаторен модул, изчисляващ най-ефективните прогнозни резултати за факторите и представящ ги на модула за прогнозиране на електропотреблението.

Прогнозиране с НКС

С помощта на НКС е извършено прогнозиране за една година напред на използваните фактори на потреблението и самата консумация на електроенергия в НЕЕС. За извадка са използвани данни от (НСИ-Енергетика, 2019) и (Инфостат-НСИ, 2022) за периода 2000-2019

година, а прогнозираните стойности на използваните като входни данни стойности на факторите за 2020 година са представени в табл. 5.

Таблица 5. Стойности на факторите, влияещи на електропотреблението според НКС за 2020 г.

Фактор	Избор на най-ефективен метод за прогнозиране според НКС	Прогнозирана стойност за 2020 г.	Статистически данни за 2020 г.	Абсолютна грешка
Брутен вътрешен продукт	Невронна мрежа	114885.46 млн. лв.	102649 млн. лв.	12236,46 млн. лв
Енергийна интензивност	Времеви ред с логаритмичен тренд	0.35	Към 31.12.2021 г. няма официални статистически данни	-
Численост на населението	Времеви ред с линеен тренд	6880484	6916548	36064
Среден годишен доход на едно лице	Невронна мрежа	6196,57 лв.	6394 лв.	197,43 лв.
Цена на електроенергията за индустрията	Невронна мрежа	21,78 ст./kwh	19,46 ст./kwh	2,32 ст./kwh
Цена на електроенергията за битови консуматори	Невронна мрежа	22,56 ст./kwh	20,32 ст./kwh	2,24 ст./kwh

Според изградената НКС, на база използваните извадки от данни, времевите редове са подходящи от ИНМ при два от факторите – енергийна интензивност на икономиката и числеността на населението, съответно с логаритмичен и линеен тренд. За прогнозиране на останалите фактори, които използваме – БВП, Среден годишен доход и цените на електроенергията за индустрията и бита, според НКС, ИНМ имат предимство пред времевите редове и резултатите са въз основа на техния избор.

Таблица 6. Прогнозирани от НКС стойности на електропотреблението по сектори

Сектор на потреблението	Прогнозирана стойност за 2020 г. в хил. т.н.е	Статистически данни за 2020 г. хил. т.н.е	Абсолютна процентна грешка / точност на прогнозата в %
Общо енергийно потребление за цялата енергийна система.	9713,99	9512,7	2,1 % / 97,9 %
Потребление в сектор „Индустрия“.	2682,4	2646,4	1,4 % / 98,6 %
Потребление в домакинствата.	2333,3	2382,2	2,1 % / 97,9 %

Прогнозите на НКС за различните видове електропотребление са представени в табл. 6. За разлика от всички описани до тук случаи, сега вече входни данни на ИНМ са едновременно всички описани фактори: БВП, енергийна интензивност на икономиката, численост на населението, среден годишен доход, цените на електроенергията за бита и индустрията.

Прогнозиране на други величини с НКС

С помощта на НКС беше прогнозирана загубата на електроенергия в НЕЕС на страната за периода 2020-2024 г., като резултатите сочат продължаващо намаляване на тези стойности. Едно възможно обяснение за намаляване на загубите за този период е тенденцията за

намаляване на стойностите на енергийната интензивност и респективно, въвеждане на все по-нови енергоспестяващи технологии и нарастване на енергийната ефективност както в индустрията, така и в бита.

Друга практическа проверка на създадената НКС се изразява в краткосрочни прогнози на консумацията на електрическата енергия, при което образците за обучение са в рамките на едно денонощие. Когато използвахме товарите на енергийната система през първите 23 часа от денонощието като образци за обучение и прогнозирахме консумацията за последния час от денонощието **отчетените грешки бяха в границите 0,05-3,3%.**

Следващата проверка се състоя в **прогнозиране на потреблението за конкретен час, основавайки се на консумацията за този час през 18 поредни предходни дни.** Тук са открити няколко идентични ИНМ с трансферна функция в тялото на невроните в скрития слой – тангенс хиперболичен и обучени по метода на Бейсовата регуларизация. **Грешките при прогнозирането варират от 0,04% до 1,64%.**

НКС намери и **реално практическо приложение при изчисляване на потреблението на електроенергия за собствените нужди на конкретен енергиен обект в един от мрежовите експлоатационни райони на страната.** За разлика от предходните проверки на НКС, които се базираха на сравнително малко количество данни, сега с помощта на МЕР-Пловдив разполагахме с голям обем от данни непрекъснато снемани всеки час за периода (01.01.2018г. – 15.02.2021 г.). За обучение на ИНМ в НКС са използвани 26304 входно-изходни образци. При подаване на данните към НКС е създадена ИНМ, която прогнозира 1080 допълнителни точки (ежечасно, за период от 45 дни след края на извадката). **Процентните абсолютни грешки, за съответните часове са в интервала (0,015% - 11,2%).**

Най-същественият извод от направените допълнителни експерименти е, че **създадената НКС би могла да се ползва за множество различни задачи за прогнозиране, без потребителя да се налага да познава в детайли вградените в нея алгоритми и методи за прогнозиране.**

Изводи

В настоящата глава са предложени модел и архитектура на автоматизирана НКС за прогнозиране на електропотреблението. Представени са основните модули в архитектурата на НКС, съответстващи на отделните етапи в процеса на прогнозиране. Моделирани са основни алгоритми за прогнозиране в системата. В реализацията са използвани предложените в глави 2 и 3 алгоритми за прогнозиране чрез търсене на най-ефективните числени методи и оптимална ИНМ.

Представени са основите модули на изградения, в средата MatLab, прототип на НКС. Прототипът позволява използване на входни-изходни данни (за обучението на методите за прогнозиране) с произволни размерности, което дава възможност за: лесно тестване на различни фактори чрез добавянето или премахването им от входните данни; използване на НКС при решаването на други задачи, които не са свързани с електропотреблението. Интегрирани в прототипа са алгоритми за откриване на най-ефективния метод за прогнозиране чрез числени методи, както и за търсене на оптимална ИНМ.

Въз основа на входно-изходните образци, НКС автоматизирано извежда прогнозни резултати както за факторите, разглеждани като времеви редове, така и за крайната целева величина, която за конкретната задача е електропотреблението. Възможностите на НКС са изпитани и с проведените експерименти за прогнозиране на други величини в енергетиката.

Като важен резултат от използването на НКС може да се определи автоматизирането на процеса на прогнозиране, което спестява огромно количество часове за търсене на ефективни методи за прогнозиране с участието на човек. Това е мощен инструмент, който може да насочи изследователя към най-подходящия за прилагане прогнозен метод, който при необходимост може да усъвършенства извън НКС.

Основен извод е, че използването на НКС би улеснило неимоверно работата на изследователите при решаване на конкретни задачи за прогнозиране.

Оптимизирането и ускоряването на работата на различни компоненти от НКС, в различни аспекти, трябва да са приоритет при бъдещо развитие на системата.

Функционалност, която би улеснила изследователите по отношение на изследваните входно-изходни величини, а също и на взаимовръзките между тях, е за разнообразни автоматично генерирани диаграми и сравнителни таблици.

Глава V. Оптимизиране на НКС

Съвсем очаквано, при по-големи обеми на входно-изходните данни, изпълнението на итеративният алгоритъм за автоматизирано търсене на оптимална ИНМ, отнема относително дълъг период от време. При работата му се създават и обучават голям брой ИНМ с различни стойности на параметри като брой неврони в скрития слой, методи за обучение, трансферни функции и епохи.

Едно от възможните решения е използването на облачни или други паралелни услуги за едновременно обучение на различни ИНМ, което ще ускори процеса по получаването на резултатната оптимална ИНМ. Разбира се, в този случай, сумарно използваните хардуерни ресурси е възможно да бъдат и в по-голям обем спрямо ресурсите при итеративния подход. Проучването на възможностите предлагани от MatLab или от други езици и системи, с които може да се реализира НКС не са предмет на настоящото изследване.

Друг резултат, получен в рамките на дисертационното изследване, е свързан с намирането на оптимален брой неврони в скритите слоеве, към който изследователите или алгоритъма за търсене на оптимална ИНМ да се насочат при изграждането на ИНМ.

Параметри, влияещи на броя на невроните в скрития слой

Много от изследователите, работещи в сферата определена от теорията на ИНМ, са насочвали през годините своето внимание към разрешаването на този проблем, и всички те са постигали само частичен успех. Различни формули за броя на невроните в скрития слой N_h са предлагани през годините (табл. 50). Използвани параметри в тях са: N_i - брой на входовете (в част от литературата се интерпретира като входни неврони); N_t - брой на образците за обучение на мрежата; N_o - брой на изходните неврони.

На пръв поглед изглежда, че функцията, която представя броя на невроните би следвало да е обхваща всички променливи: N_h е брой на невроните в мрежата; N_l – брой на скритите слоеве; N_i – брой на входните стимули/размерност на входния вектор; N_o – броя на изходните неврони; N_t – броя на образците за обучение; T_l – тип на обучението; G – тип на активиращата функция; E – избран максимален брой на епохите при обучението; W и B – съответните матрици от първоначално инициализирани тегла и прагове; V – степен на разсейване (хаотичност) на образците за обучение – вид на корелационното поле; I – интервал (диапазон на интервала) от входните данни.

Предвид доказаната от Cybenko теорема (Cybenko, G., 1989), можем да фиксираме $N_l = 1$, и да поставим условието за сигмоиден характер на непрекъснатата активираща функция

$$G(x) = \begin{cases} 1, & x \rightarrow +\infty \\ 0, & x \rightarrow -\infty \end{cases}$$

Така, що се касае до апроксимиращи НМ, имаме две променливи, от които в определени практически случаи може да се откажем – броя на скритите слоеве N_l и типа на активиращата функция G . При тези условия броят на невроните може да се определи като:

$$N_h = F(N_i, N_o, N_t, T_l, E, W, B, V, I).$$

Възможно ли е да се освободим от влиянието на други от описаните фактори? Отговорът на този въпрос е все още открит. Дори самият факт, че разработчиците на софтуер специализиран за моделиране на ИНМ са оставили възможността на потребителите сами да определят броя на невроните, без намеса и предложения за оптималния вариант, индиректно, но красноречиво говори за липсата на точен отговор.

В дисертацията е изследвано влиянието на броя на входните стимули и броя примерите за обучение върху оптималния брой неврони и е установено, че оптималния брой на невроните е обратнопропорционален на размерността на входния вектор $N_h \sim \frac{1}{N_i}$ и право пропорционален на броя на примерите за обучение $N_h \sim N_t$.

Формула за горна граница на невроните в НМ с един скрит слой, при обучение, основано на алгоритъма на Гаус и Нютон

При изследване на определените зависимости търсим формула, даваща ни представа за оптималния брой неврони, разглеждаме НМ с един скрит слой и сигмоидна трансферна функция. Разглеждайки математическия модел, върху който са изградени алгоритмите за обучение, използващо матрицата на Якоби, получаваме формула за която ни дава информация за горна граница на необходимия брой неврони в скрития слой за оптимална НМ:

$$q \leq \frac{m - 1}{n + 2},$$

където

- q е горната граница на оптималния брой неврони,
- m – броя на образците за обучение,
- n – броя на входните променливи.

Проведените последващи експерименти потвърждават, че броят на невроните за изгражданите НМ не надхвърля предварително пресметнатия чрез предложената формула.

Горна граница на броя на невроните при мрежи с r скрити слоя

Разглеждайки случай на НМ с r скрити слоя, съдържащи равен брой неврони, с математически изчисления е определена формула за горна граница на нужния брой неврони в скритите слоеве:

$$Q = \frac{\sqrt{(r + n + 1)^2 + 4(r - 1)(m - 1)} - (r + n + 1)}{2(r - 1)} r.$$

Изводи

Получените, в резултат на представеното в настоящата глава изследване, **формули дават удобен инструмент за определяне на горна граница на невроните, необходими за обучение на оптимална ИНМ, при методи за обучение като Levenberg-Marquardt, Гаус-Нютон, Bayesian Regularization, Scaled Conjugate Gradient, BFGS Quasi-Newton и др.**, използващи матрицата на Якоби.

Изследвания за влиянието на други параметри върху оптималния брой на невроните в скритите слоеве за сега не са дали ефективни резултати и могат да бъдат предмет на допълнителни изследвания.

Заклучение

През последните години, интересът към системите, базирани на ИНМ се завръща и засилва, заедно с увеличаване на изчислителната мощ на съвременните компютърни системи. ИНМ успяват да се справят с проблеми, при които традиционните алгоритми се провалят.

Създаденият прототип на НКС за прогнозиране притежава някои важни положителни качества, които допринасят за неговата ефективност и го отличават от готовите модули, като тези на Matlab, Orange, Tibco Software Inc или Python, описани например от (Demuth, H.; Beale, M., 2004), (Demša, J.; Erjavec, T., 2013), (Alperin, M.; Waehner, K., 2016), (Fonseca, A.; Cabral, B., 2015):

1. Обработка на данните от гледна точка на конвенционалните методи и ИНМ.
2. Използване на времеви редове с девет различни вида функции на тренда.
3. Възможност за сравняване на ефективността на всеки от методите и използване на най-ефективния за всеки отделен фактор на потреблението.
4. Промяната на броя на невроните при изграждане на ИНМ се извършва автоматично, без да е необходима намеса от страна на потребителите.
5. Неограничен брой на невроните в скрития слой, в сравнение с инструмента Neural Fitting.
6. При необходимост от смяна на метода за обучение, НКС, без намеса и настройки от страна на потребителите се грижи за повторното обучение на мрежата с избор на нов метод. За разлика от готовите модули, при НКС се използва по-голям набор от методи за обучение.
7. Автоматично изпробване на различни активиращи функции за невроните от скрития слой.
8. Автоматичната промяна на броя на епохите при обучението на ИНМ. Това дава възможност за откриване на ефективни мрежи с по-малък брой на невроните.
9. Освен основните прогнозните данни, НКС извежда допълнителна информация, която може да бъде интерпретирана и използвана при необходимост. Напр. може да се направи оценка на теглата на отделните фактори, която ни дава представа за това доколко важен е всеки един от тях за общото потребление.

Една възможност за усъвършенстване на НКС е добавянето на **допълнителен модул за прогнозиране** на факторите и целевата величина **чрез средствата на генетичните алгоритми**.

Тривиални и вече разглеждани възможности за усъвършенстване на НКС са в насоки, които може да включват използването и на други езици за програмиране:

- реализация на **паралелни, облачни алгоритми за по-бързо намиране на оптимална ИНМ** или/и търсене на **евристични правила за по-ефективната му работа**.
- **изграждане на графичен-потребителски интерфейс**, с цел по-лесно използване от потребителите;
- **автоматизирано генериране на подходяща документация**, с резултати от изчисленията на НКС, **съдържаща таблици, диаграми и др.**
- **в случая на електропотреблението, търсене на нови геополитически, икономически и др. фактори**, със значимо влияние.

Приноси

Приносите на дисертационното изследване може да бъдат класифицирани като научни, научно-приложни и приложни.

1. Създаден е модел на автоматизирана НКС за прогнозиране на електропотреблението.
2. Изведени са две формули за оптимална горна граница на броя на невроните при ИНМ, обучавани с методи, използващи матрицата на Якоби – за ИНМ с един скрит слой и с няколко скрити слоя.
3. Разработена е архитектура на НКС за прогнозиране на електропотреблението.
4. Проектирани и реализирани в MatLab са алгоритми за:
 - откриване на статистически значими корелационни коефициенти;
 - намиране на най-ефективния модел на линейна регресия;
 - най-ефективно прогнозиране чрез екстраполация;
 - най-ефективно прогнозиране чрез времеви редове;
 - автоматизирано конструиране на оптимална ИНМ за прогнозиране и др.
5. Реализиран е прототип на НКС за прогнозиране на електропотреблението.
6. Тествана е работата на създадената НКС и са анализирани получените резултати.

Апробация

Работата на изградената НКС е изпробвана при прогнозиране както на факторите, така и на различните видове електропотребление. Грешките в електропотреблението, допускани от създадените ИНМ, са в рамките на 1,4-2.1% при сравнение на абсолютните стойности на прогнозите и реалните данни за последната година – 2020 г. – за която има налични данни в момента на приключване на изследванията.

Минимални процентни абсолютни грешки се получават при повечето от проведените допълнителни експерименти за прогнозиране.

Проекти

Получените по време на изследването резултати са представяни в три научно-изследователски проекта:

- СП19-ФМИ-004, „Формиране на научни компетентности в Студентска школа за ИКТ иновации“ (2019-2020).
- СП19-ФМИ-012, „Моделиране на невронни мрежи с приложения в бизнеса“ (2020).
- МУ21-ФМИ-004, „Подкрепа за провеждане на научни изследвания в Школа за ИКТ иновации“ (2021-2022).

С финансовата подкрепа на споменатите проекти, резултатите са докладвани на три конференции и три семинара.

Доклади на научни конференции

1. *Influence of the Price of Electricity for the Industry on the Consumption in the Economic Sector in Bulgaria*, International Conference on Technics, Technologies and Education ICTTE 2020, November 4-6, 2020, Yambol, Bulgaria.
2. *Forecasting Energy Efficiency and Energy Consumption in Bulgaria by Examining the Energy Intensity Indicator Using Neural Networks*, 21-st International Symposium on Electrical Apparatus and Technologies (SIELA), 3 - 6 June 2020, Bourgas, Bulgaria.

3. *Автоматизирано конструиране и обучение на невронни мрежи в MatLab*, Конференция на Съюз на учените – гр. Пловдив, Научна сесия „Дни на науката 2018“, 2 – 3.11.2018, гр. Пловдив.

Доклади на научно-изследователски и образователни семинари

1. *Конструиране на изкуствени невронни мрежи с MatLab*, Обучителен семинар, 15.11.2019 г., гр. Пловдив.
2. *Система за избор на най-ефективен метод за прогнозиране чрез статистически анализ, времеви редове и изкуствени невронни мрежи*, Научен семинар "Моделирание на невронни мрежи с приложения в бизнеса", 13.11.2020 г.
3. *Краткосрочно прогнозиране с изкуствени невронни мрежи*, XVII Научен семинар на Школа за ИКТ иновации, 29.11.2021 г.

Резултатите от дисертационното изследване са отпечатани в шест научни публикации.

Списък с публикации по темата на дисертационния труд

1. **Yotov, K.**, E. Hadzhikolev, S. Hadzhikoleva, *Model for Forecasting of Electricity Losses During Transmission and Distribution in an Electricity System*, International Journal of Engineering Trends and Technology, vol. 69, issue 6, pp. 93 - 98. **(SCOPUS)**
2. **Yotov, K.**, E. Hadzhikolev, S. Hadzhikoleva, *Influence of the Price of Electricity for the Industry on the Consumption in the Economic Sector in Bulgaria*, IOP Conference Series: Materials Science and Engineering, 2021, 1031(1), Article number 012084. **(SCOPUS)**
3. **Yotov, K.**, E. Hadzhikolev, S. Hadzhikoleva, *Determining the Number of Neurons in Artificial Neural Networks for Approximation, Trained with Algorithms Using the Jacobi Matrix*, TEM Journal, vol. 9, No. 4, pp. 1320–1329, 2020, ISSN: 2217-8309. **(SCOPUS, SJR = 0.199, Web of Science)**
4. **Yotov, K.**, E. Hadzhikolev, S. Hadzhikoleva, *Forecasting Energy Efficiency and Energy Consumption in Bulgaria by Examining the Energy Intensity Indicator Using Neural Networks*, 21-st International Symposium on Electrical Apparatus and Technologies (SIELA) - Proceedings, 2020, 3 - 6 June 2020, Bourgas, Bulgaria, pp. 523-526, ISBN 978-1-7281-4345-3. **(SCOPUS)**
5. **Yotov, K.**, E. Hadzhikolev, S. Hadzhikoleva, *Forecasting Electricity Consumption in Bulgaria by Studying its Dependence on Socio Economic And Demographic Variables*, International Journal of Scientific & Technology Research, vol. 9, issue 4, pp. 705–710, 2020, ISSN 2277-8616. **(SCOPUS)**
6. **Йотов, К.**, Е. Хаджиколев, С. Хаджиколева, *Автоматизирано конструиране и обучение на невронни мрежи в MatLab*, Научни трудове на Съюза на учените в България – Пловдив. Серия В. Техника и технологии. Том XVII, ISSN 1311 -9419 (Print); ISSN 2534-9384 (Online), 2019, стр. 114-124.

Забелязани цитирания

1. **Yotov, K.**, E. Hadzhikolev, S. Hadzhikoleva, *Determining the Number of Neurons in Artificial Neural Networks for Approximation, Trained with Algorithms Using the Jacobi Matrix*, TEM Journal, vol. 9, No. 4, pp. 1320–1329, 2020, ISSN: 2217-8309.

1. Georgiev, M., A. Georgieva, D. Gospodinova and K. Milanov, *Neural Networks Application for Modelling of RES production*, 2021 13th Electrical Engineering Faculty Conference (Bulef), 2021, pp. 1-6, DOI: 10.1109/Bulef53491.2021.9690840.
2. Prudencio, G., C. Celis, J.S. Armacanqui, et al., *Development of an evolutionary artificial neural network-based tool for selecting suitable enhanced oil recovery methods*, Journal of the Brazilian Society of Mechanical Sciences and Engineering, vol. 44, Article number: 121 (2022). DOI: 10.1007/s40430-022-03403-3.
2. **Yotov, K.**, E. Hadzhikolev, S. Hadzhikoleva, *Forecasting Electricity Consumption in Bulgaria by Studying its Dependence on Socio Economic And Demographic Variables*, International Journal of Scientific & Technology Research, vol. 9, issue 4, pp. 705–710, 2020, ISSN 2277-8616.
3. Tomov, L. (2021) *Modeling seasonality of net electrical consumption in Bulgaria*, Conference: Computer Science and Computer Science Education, 2021.

Библиография

- Alperin, M.; Waehner, K. (2016). *Machine Learning in Manufacturing: Data Mining to Real-time Processing*. TIBCO Software Inc.
- Cervená, M.; Schneider, M. (2014). Short-term forecasting of GDP with a DSGE model augmented by monthly indicators. *International Journal of Forecasting, Volume 30, Issue 3*, pp. 498-516.
- Chernykh, I.; Chechushkov, D.; Panikovskaya, T. (2014). Prediction of electrical loads in operational control of power systems based on neural network structures. *WIT Transactions on Ecology and the Environment, vol. 190*, 109 - 117.
- Chung, Y. (2017). Electricity consumption prediction using a neural-network-based grey forecasting approach. *Journal of the Operational Research Society, Volume 68, Issue 10*, pp. 1259 - 1264.
- Cybenko, G. (1989). Approximation by Superpositions of a Sigmoidal Function. *Mathematics of Control, Signals and Systems, vol. 2*, 303 - 314.
- Demša, J.; Erjavec, T. (2013). Orange: Data Mining Toolbox in Python. *Journal of Machine Learning Research, vol. 14*, pp. 2349-2353.
- Demuth, H.; Beale, M. (2004). *Neural Network Toolbox*. Natick, MA 01760-2098: The MathWorks, Inc.
- Ding, S.; Hipel, K.; Dang, Y. (2018). Forecasting China's electricity consumption using a new grey prediction model. *Energy, Vol. 149*, pp. 314 - 328.
- Fonseca, A.; Cabral, B. (2015). Designing a Neural Network from Scratch for Big Data Powered by Multi-node GPUs. *Handbook of Deep Learning Applications. Smart Innovation, Systems and Technologies, vol 136* (pp. 1-19). Springer.
- Hu, Yi-Chung. (2017). Electricity consumption prediction using a neural-network-based grey forecasting approach. *Journal of the Operational Research Society*, pp. 1259–1264.
- Huang, Y.; Wang, C.; Dang, H.; Lai, S. (2016). Evaluating performance of the DGM(2,1) model and its modified models. *Applied Sciences, vol. 6(3)*, p. 73.

- Hyndman, R.; Athanasopoulos, G. (2018). *Forecasting: Principles and Practice*. Извлечено от O Texts: <https://otexts.com/fpp2/>
- Jahn, M. (2018). *Artificial neural network regression models: Predicting GDP growth*, HWWI Research Paper, No. 185. Hamburg: Hamburg Institute of International Economics (HWWI).
- Karatasou, S.; Santamouris, M.; Geros, V. (2008). Modeling and predicting building's energy use with artificial neural networks: Methods and results. *Energy and Buildings, Volume 38, Issue 8*, pp. 949–958.
- Khosravani, H.; Castilla, M.; Berenguel, M.; Ruano, A; Ferreira, P. (2016). A Comparison of Energy Consumption Prediction Models Based on Neural Networks of a Bioclimatic Building. *Energies, vol. 9(1)*, 57.
- Lee, Y. S.; Tong, L.T. (2011). Forecasting energy consumption using a grey model improved by incorporating genetic programming. *Energy Conversion and Management, Volume 52, Issue 1*, pp. 147-152.
- Lee, Y.; Gaik, T.; Yee, Ch. (2018). Forecasting Electricity Consumption Using Time Series Model. *International Journal of Engineering & Technology, vol. 7, n. 4.30*, 218-223.
- Miikkulainen, R. (2011). *Topology of a Neural Network*. Boston: Springer, Boston, MA.
- Mohamed, Z.; Bodger, P. (2005). Forecasting electricity consumption in New Zealand using economic and demographic variables. *Energy, Volume 30, Issue 10*, 1833–1843.
- O'Neil, C.; Schutt, R. (2013). *Doing Data Science*. O'Reilly Media, ISBN: 9781449358655.
- Risk Management Lab. (2014). *Прогноза на електроенергийния баланс на Р. България 2025 г.* . Retrieved from БСК: https://www.bia-bg.com/uploads/files/events/Energy_balans_BG2025.pdf
- Sun, T.; Zhang, T.; Teng, Y.; Chen, Z.; Fang, J. (2019). *Monthly Electricity Consumption Forecasting Method Based on X12 and STL Decomposition Model in an Integrated Energy System*. Aalborg: Department of Energy Technology, Aalborg University, Aalborg 9220, Denmark.
- Yoo, S.; Myriam, H. A. (2018). Predicting residential electricity consumption using neural networks: A case study. *Journal of Physics: Conference Series, Volume 1072, 012005*.
- БАН-стратегия. (2017). *Изготвяне на Национална стратегия в областта на енергетиката*. София: БАН.
- Гочева-Илиева, С. (2013). *Компютърни числени методи*. Пловдив: Университетско издателство "Паисий Хилендарски".
- Гочева-Илиева, С. (2014). *Иконометрия Лекции 6-8*.
- Дамгалиев, Д.; Теллалян, Ж. (2006). *Бизнесстатистика*. Нов Български университет.
- Дудел, Дж.; Рюегг, И.; Шмидт, Р.; Яниг, В. (1985). *Физиология человека*. Москва: Издателство "Мир".

Инфостат-НСИ. (2022). Извлечено от Инфостат - Национален статистически институт:

https://infostat.nsi.bg/infostat/pages/module.jsf?x_2=131&lang=bg

Кирова, Т. (1995). *Невронни мрежи – Основни архитектури и обучаващи алгоритми*. София:

Tempusd Jen 1497 Софттех.

Мишева, М.; Шишков, Д. (1995). *Изкуствен интелект*. Добрич: Издателство "Интеграл".

НСИ-Енергетика. (Юни 2019 г.). *Енергетика: Национален статистически институт*.

Изтеглено на 2019 от Национален статистически институт:

<http://www.nsi.bg/bg/content/4097/%D0%B5%D0%BD%D0%B5%D1%80%D0%B3%D0%B5%D1%82%D0%B8%D0%BA%D0%B0>

Съйкова, И. (1981). *Статистически анализ на връзки и зависимости*. София: Издателство

"Наука и изкуство".