



ТЕХНИЧЕСКИ УНИВЕРСИТЕТ – СОФИЯ
Електротехнически Факултет
Катедра Електроенергетика

маг. инж. Таньо Иванов Танев

**ИЗСЛЕДВАНЕ НА РЕЖИМИТЕ НА РАБОТА НА
ФОТОВОЛТАИЧНИ ЕЛЕКТРИЧЕСКИ ЦЕНТРАЛИ**

А В Т О Р Е Ф Е Р А Т

на дисертация за придобиване на образователна и научна степен
"ДОКТОР"

Област: 5. Технически науки

Професионално направление: 5.2. „Електротехника, електроника и
автоматика“

Научна специалност: „Електрически централи и подстанции“

Научен ръководител: доц. д-р инж. Рад Станев

СОФИЯ, 2025 г.

Дисертационният труд е обсъден и насочен за защита от Катедрения съвет на катедра „Електроренергетика“ към Електротехнически Факултет ТУ-София на редовно заседание, проведено на 10.12.2025 г.

Публичната защита на дисертационния труд ще се състои на 14.04.2026 г. от 13,00 часа в Конферентната зала на БИЦ на Технически университет – София на открито заседание на научното жури, определено със заповед № ОЖ-52-91 / 22.12.2025 г. на Ректора на ТУ-София в състав:

1. доц. д-р Ива Димитрова Драганова-Златева – председател
2. проф. д-р Ангел Белчев Цолов – научен секретар
3. доц. д-р Юлиян Емилов Рангелов
4. доц. д-р Николай Деянов Николаев
5. доц. д-р Медиха Енвер Мехмед

Рецензенти:

1. проф. д-р Ангел Белчев Цолов

Материалите по защитата са на разположение на интересуващите се в канцеларията на Електротехнически Факултет на ТУ-София, блок № 12, кабинет № 12 425.

Дисертантът е задочен докторант към катедра „Електроенергетика“ на Електротехнически факултет. Изследванията по дисертационната разработка са направени от автора, като някои от тях са подкрепени от научноизследователски проекти.

Автор: маг. инж. Таньо Танев

Заглавие: Изследване на режимите на работа на фотоволтаични електрически централи

Тираж: 30 броя

Отпечатано в ИПК на Технически университет – София

1. ОБЩА ХАРАКТЕРИСТИКА НА ДИСЕРТАЦИОННИЯ ТРУД

Актуалност на проблема

През последните години се наблюдава интензивно нарастване на дела на фотоволтаичните електроцентрали (ФЕЦ), присъединени към електроенергийните системи, което е пряко обусловено от глобалните тенденции за декарбонизация, повишаване на енергийната ефективност и устойчиво развитие. Фотоволтаичната генерация е със силно изразена зависимост от метеорологичните условия и от това произтича стохастичност на процеса на производство на електроенергия. Тази особеност затруднява планирането, управлението и експлоатацията на електроенергийните системи с висок дял на фотоволтаични източници.

Поради това, се увеличава нуждата от точно и надеждно прогнозиране на производството на електроенергия от ФЕЦ в различни времеви хоризонти. Неточностите в прогнозите могат да доведат до икономически загуби, увеличени балансиращи разходи и влошаване на сигурността на електроенергийната система.

Съществуващите класически подходи за моделиране и прогнозиране на производството от фотоволтаични електроцентрали често се базират на опростени физически модели или статистически методи, които не винаги успяват да обхванат линейните и сложните нелинейни зависимости между слънчевата радиация, метеорологичните параметри и електрическата генерация. Поради това, през последното десетилетие все по-широко приложение намират методите на машинното обучение и дълбокото обучение, които предоставят възможност за извличане на скрити зависимости от големи обеми данни и за повишаване на точността на прогнозите.

От своя страна, прилагането на съвременни алгоритми за машинно обучение поставя допълнителни предизвикателства, свързани с избора на подходящи модели, оптимизацията на техните хиперпараметри и интерпретацията на получените резултати. Липсата на унифицирана методология за оптимизиране на хиперпараметрите, и систематично сравнение и оценка на различни модели и подходи ограничава тяхното практическо приложение и затруднява вземането на информирани инженерни решения.

В допълнение, интегрирането на фотоволтаични електроцентрали със системи за съхранение на електрическа енергия добавя технически възможности, но увеличава нуждата от моделиране и прогнозиране.

Направеният анализ на съществуващите научни публикации показва, че въпреки значителния брой изследвания в областта, липсва цялостен и систематичен подход, който да обединява моделирането и прогнозирането на

производството на електроенергия от ФЕЦ чрез съвременни методи за машинно обучение, оптимизацията на техните параметри. Това обуславя актуалността и научно-приложната значимост на разработвания в настоящия дисертационен труд проблем.

Цел на дисертационния труд, основни задачи и методи за изследване

Целта на настоящия дисертационен труд е да се изследват режимите на работа на фотоволтаични електрически централи, като се разработят, приложат и валидират методологии и алгоритми за математическо моделиране и прогнозиране на производството на електроенергия и на основните елементи на фотоволтаичните електроцентрали, базирани на съвременни методи за машинно и дълбоко обучение.

За постигане на поставената цел в дисертационния труд, е извършен литературен обзор, на базата на който, са формулирани основни задачи.

1. Анализ и обобщение на съвременните подходи с методи за машинно обучение за моделиране и прогнозиране на производството на електроенергия от фотоволтаични електроцентрали.

2. Математическо моделиране на производството на електроенергия на ФЕЦ чрез моделиране на масив от фотоволтаичните модули.

3. Моделиране на производството на електроенергия на ФЕЦ чрез математическо моделиране на ефективността и производителността на ФВ инвертори.

4. Моделиране на напрежението в реални работни режими на батерийна система за съхранение на енергия, интегрирана към ФЕЦ.

5. Прилагане и сравнение на методи за машинно обучение за прогнозиране на производството на електроенергия на ФЕЦ въз основа на исторически данни на основните, най-значимо влияещи фактори (слънчевата радиация и температура на околната среда).

6. Прогнозиране на производството на електроенергия на ФЕЦ, в краткосрочен хоризонт (ден напред), чрез прогнозиране на слънчевата радиация с помощта на времеви серии.

7. Анализ на резултатите и извеждане на препоръки относно приложимостта и точността на предложените модели в рамките на различни климатични и експлоатационни условия.

Научна новост

В дисертационния труд са разработени и валидирани методологии за моделиране на елементи от ФЕЦ, както и прогнозиране на производството на електроенергия от фотоволтаични електроцентрали, базирани на съвременни методи за машинно и дълбоко обучение. За целите на изследването е използвана структурирана база от реални експлоатационни и метеорологични

данни, която позволява коректно обучение, валидиране и сравнение на различни модели при унифицирани условия.

Изследвани са както математически методи, така и методи за машинно обучение, и съвременни невронни архитектури, като е анализирано влиянието на избора на модел и оптимизацията на хиперпараметрите върху точността на прогнозите. Научна новост представлява систематичният сравнителен анализ на различни подходи за прогнозиране, извършен върху едни и същи входни данни и с използване на унифицирани критерии за оценка.

Практическата приложимост на резултатите се изразява във възможността разработените модели да бъдат интегрирани в системи за планиране и управление на фотоволтаични електроцентрали и системи за съхранение на електрическа енергия, подпомагайки вземането на информирани решения при експлоатацията и управлението на режимите на работа.

Предложените методологии са приложими за фотоволтаични електроцентрали с различна мощност и конфигурация и могат да бъдат използвани, както в инженерната практика, така и в учебния процес.

Методология

В изследванията са използвани математически модели и софтуерни инструменти за анализ и моделиране на режимите на работа на фотоволтаични електрически централи и батерийни системи за съхранение на енергия. Прилагани са както детерминистични модели, така и подходи, базирани на машинно обучение, при които системите се разглеждат като „черни кутии“, с цел повишаване на практическата приложимост на анализа и прогнозата въз основа на реални експлоатационни данни.

Практическа приложимост

Получените резултати са приложими при анализ и прогнозиране на режимите на работа на фотоволтаични електрически централи с (или без) интегрирани батерийни системи, като подпомагат планирането и експлоатацията на електроенергийни системи с високо участие на възобновяеми енергийни източници.

Апробация

Основните резултати от проведените изследвания са проверени чрез сравнителни софтуерни аналитични мероприятия.

Публикации

Основните постижения и резултати от дисертационния труд са публикувани в шест публикации, от които шест са в съавторство. Всички публикации са представени на международни конференции и са видими в IEEE и MDPI.

Структура и обем на дисертационния труд

Дисертационният труд е в обем от 233 страници, като включва увод, три глави за решаване на формулираните основни задачи, списък на основните приноси, списък на публикациите по дисертацията и използвана литература. Цитирани са общо 209 литературни източници, всички на латиница, а пет от тях са интернет адреси. Работата включва общо 41 фигури и 6 броя таблици. Номерата на фигурите и таблиците в автореферата съответстват на тези в дисертационния труд.

2. СЪДЪРЖАНИЕ НА ДИСЕРТАЦИОННИЯ ТРУД

ГЛАВА I. ЛИТЕРАТУРЕН ОБЗОР

В резултат на извършения литературен обзор са анализирани 209 литературни източника, включващи научни публикации в рецензирани списания и сборници от международни конференции, както и специализирани интернет източници.

Въз основа анализа на съществуващите изследвания, за постигане на поставената цел в дисертационния труд са формулирани и решени следните основни задачи:

1. Анализ и обобщение на съвременните подходи с методи за машинно обучение за моделиране и прогнозиране на производството на електроенергия от фотоволтаични електроцентрали.
2. Математическо моделиране на производството на електроенергия на ФЕЦ чрез моделиране на масив от фотоволтаични модули.
3. Моделиране на производството на електроенергия на ФЕЦ чрез математическо моделиране на ефективността и производителността на ФВ инвертори.
4. Моделиране на напрежението в реални работни режими на батерийна система за съхранение на енергия, интегрирана към ФЕЦ.
5. Прилагане и сравнение на методи за машинно обучение за прогнозиране на производството на електроенергия на ФЕЦ въз основа на исторически данни на основните, най-значимо влияещи фактори (слънчевата радиация и температура на околната среда).
6. Прогнозиране на производството на електроенергия на ФЕЦ, в краткосрочен хоризонт (ден напред), чрез прогнозиране на слънчевата радиация с помощта на времеви серии.
7. Анализ на резултатите и извеждане на препоръки относно приложимостта и точността на предложените модели в рамките на различни климатични и експлоатационни условия.

ГЛАВА II. МАТЕМАТИЧЕСКО МОДЕЛИРАНЕ НА ФОТОВОЛТАИЧНА ЕЛЕКТРОЦЕНТРАЛА И НЕЙНИ ОСНОВНИ КОМПОНЕНТИ

II.1. Общ преглед и цел на главата

Втора глава е насочена към разработване, реализиране и експериментална валидация на математически модели за описване на режимите на работа на фотоволтаична електроцентрала (ФЕЦ) и нейни ключови елементи. Главата включва три последователни изследвания:

- (1) структурен комбиниран модел на ФЕЦ, включващ фотоволтаичен генератор, DC окабеляване и инвертор;
- (2) специализиран модел за ефективност/изходна мощност на мрежов фотоволтаичен инвертор чрез мултилинейна регресия;
- (3) регресионен модел за напрежението на батерийна система за съхранение на електрическа енергия (ССЕЕ), интегрирана към ФЕЦ.

Общата цел на главата е да се демонстрира, че с подходящ баланс между физическо-структурни зависимости и емпирични модели (регресия) може да се постигне практически приложима точност, кратко изчислително време и възможност за настройване към конкретна електроцентрала, използвайки ограничен набор от измерими/достъпни входни параметри.

II.1. Комбиниран структурен модел на ФЕЦ (ФВ генератор – DC кабели – инвертор)

II.1.1. Структура, входове и изходи

Предложеният комбиниран модел следва структурен подход и включва последователно:

- (i) фотоволтаичен генератор (на ниво клетка/модул/масив),
- (ii) DC окабеляване и връзки (загуби),
- (iii) фотоволтаичен инвертор (ефективност/преобразуване към AC).

Основните входни параметри са слънчева радиация G и температура на околната среда T_a . Изходът на модела е произведената AC мощност P_{AC} , като междинно се оценяват V , I , P_{DC} , DC загуби, инверторна ефективност и др.

II.1.2. Модел на фотоволтаичната клетка и генератор

Фотоволтаичната клетка се описва чрез еднодиоден еквивалентен модел със сериен и паралелен елемент. Общият ток на клетката I се определя от:

$$\text{II.1} \quad I = I_{PV} - I_0 \left(e^{\frac{q(V+IR_S)}{nkT_{cell}}} - 1 \right) - \frac{V + IR_S}{R_{SH}}$$

където R_S е серийното съпротивление, R_{SH} – паралелното съпротивление, I_{PV} – фототок, I_0 – ток на насищане, n – коефициент на идеалност, T_{CELL} – температура на клетката, V – напрежение на клемите на клетката. Параметрите на клетката/модула се идентифицират от номинални данни на производителя (точки I_{SC} , V_{OC} , I_{MPP} , V_{MPP}).

За всеки един момент, работната температура на модулите се изчислява с помощта на опростена емпирично установена връзка като се вземе предвид температурата на околната среда T_{AMB} и слънчева радиация:

$$\text{II.2} \quad T_{CELL} = T_{AM.T.} + (T_{NOCT} - 20) \frac{G}{800}$$

За оценка на производителността и „качеството“ на волт-амперната характеристика се използва фактор на запълване (Fill Factor):

$$\text{II.3} \quad FF_{CELL} = \frac{I_{MPP} V_{MPP}}{I_{SC} V_{OC}}$$

където I_{MPP} и V_{MPP} са токът и напрежението, съответно при максимална точка на мощност (номиналната стойности на производителя). Като се имат предвид $V-A$ характеристики, може да се определи също и FF_{0CELL} , който е коефициентът, когато $R_s = 0$. R_s е:

$$\text{II.4} \quad R_s = \frac{V_{OC}}{I_{SC}} - \frac{P_{Nom}}{FF_0 I_{SC}^2}$$

След това се определят I_0 и останалите параметри за работна точка чрез итерационен процес, като за оценка на тока на насищане се използва условието при отворена верига ($I=0, V=V_{OC}$).

По този начин, за всяка точка от $V-A$ характеристиката, се записват стойности на тока и напрежението. Максималната генерирана мощност се определя като максимален резултат от умножението на съответните стойности на двата вектора:

$$\text{II.5} \quad P_{DC \max} = \max(I, V)$$

II.1.3. Загуби в DC окабеляване и връзки

DC кабелите и връзките се моделират чрез активно съпротивление, като активните загуби се оценяват с:

$$\text{II.6} \quad \Delta P_{\text{DC.CAB.}} = R \cdot I^2$$

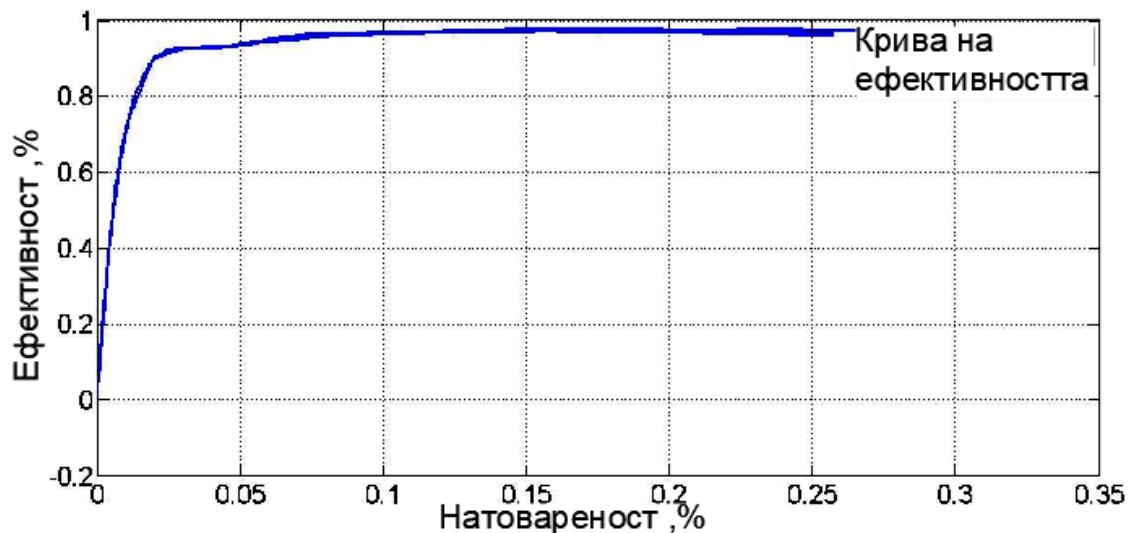
II.1.4. Модел на фотоволтаичния инвертор

Инверторът преобразува DC мощност към AC мощност. Ефективността му се апроксимира чрез емпирична полиномна зависимост от натоварването/мощността:

$$\text{II.7} \quad y = a_1 x^n + a_2 x^{n-1} + \dots + a_n x + a_{n+1}$$

В модела се приема, че влиянието на допълнителни фактори (напр. DC напрежение) може да бъде пренебрегнато с цел намаляване на изчислителното време при запазване на приемлива точност за инженерни приложения.

Фигура II-1 представя ефективността на инвертора като полиномна функция на генерираната мощност.



Фигура II-1 - Ефективност на инвертора, в зависимост от натоварването


II.1.5. Реализация и валидация

Моделът е реализиран в MATLAB, като позволява конфигуриране на топологията (брой инвертори, стрингове, модули), както и настройка на основни параметри на модулите и клетъчната им конфигурация.

Валидацията е извършена с реални данни от мрежова ФЕЦ в с. Медковец, България 103 kWp. Точността е оценена чрез средно отклонение със знак (MSD) и относителна грешка на произведената енергия. Разликата между изчислена и измерена енергия за дневен/седмичен/месечен период е около

1.6–1.8%, като се отчита, че точността на SCADA измерванията е в рамките на приблизително 1–3%.

Фигура II.2 представя мощността, изчислена с помощта на модела и действително измерената мощност за седмичен период.



Фигура II-2 - Мощност, изчислена с модела и измерена мощност за седмичен период

Резултатите показват, че основният принос към общата грешка произтича от модула за ФВ генератора, което е очаквано предвид опростяванията и зависимостта от параметризацията на I–V характеристиката.

Обобщение - комбинираният структурен модел осигурява добра изчислителна ефективност и приемлива точност и е подходящ за ФЕЦ с различни топологии и мащаби. Структурният подход позволява разширяване чрез добавяне на допълнителни блокове (напр. съхранение, зарядни устройства и др.).

II.2. Математическо моделиране на фотоволтаичен инвертор

II.2.1. Мотивация и постановка

Инверторът е ключов елемент за енергийния добив и режима на работа на ФЕЦ. За инженерни анализи често е необходим модел, който да е прост, бърз за изчисление, и адаптируем към конкретна електроцентрала въз основа на реални измервания. В изследването се предлага модел, оценяващ ефективността/изходната AC мощност на инвертора като функция на входни електрически величини, използвайки мултилинейна регресия.

II.2.2. Регресионна формулировка

Линейната регресия моделира зависимата променлива y чрез линейна комбинация на независими променливи:

$$\text{III.1} \quad y_i = b_0 1 + b_1 x_{i1} + \dots + b_p x_{ip} + e_i = X_i^T + e_i$$

Независимите променливи са входното напрежение и входната мощност като за подобряване на числената устойчивост се използва нормализация.

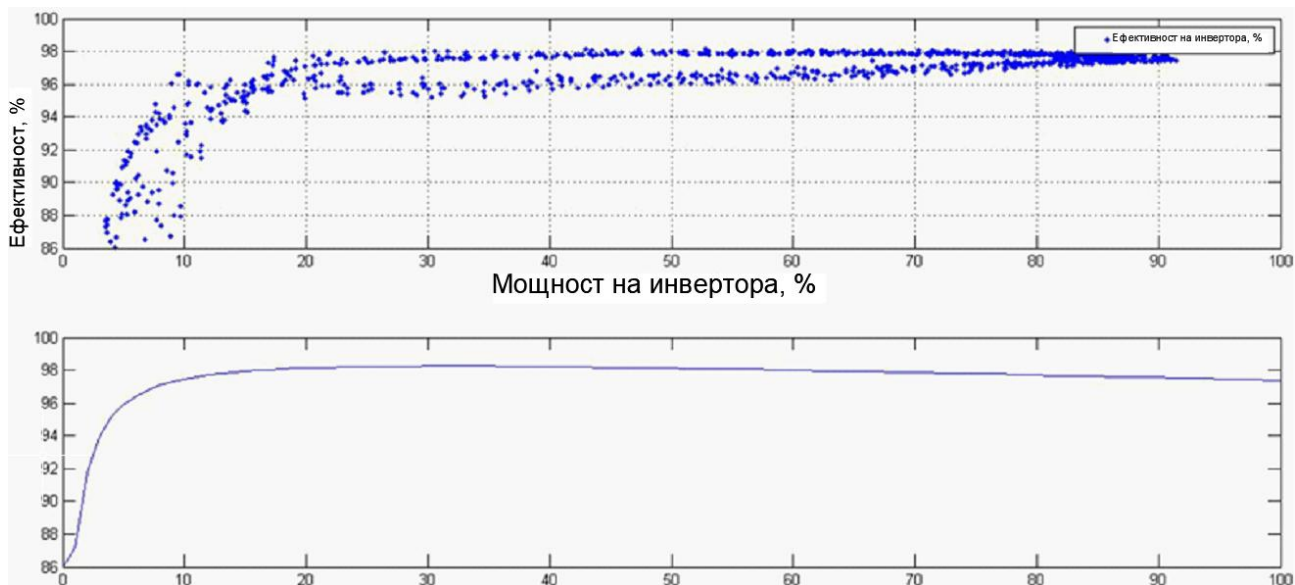
$$\eta = f\left(\frac{P_{IN}}{P_{NOM}}, \frac{V_{IN}}{V_{NOM}}\right)$$

III.2

Коефициентите β_1 , β_2 се изчисляват от измерени данни за избран период на обучение. След това те се използват за прогнозиране/моделиране на следващ период, като разликата между изчислената и измерената изходна мощност се интерпретира като грешка на модела на ефективността.

II.2.3. Валидация и анализ

Валидацията е извършена с данни от същата реална ФЕЦ (Медковец), но за по-дълъг период (05.09.2012–26.04.2013). Изследвани са различни комбинации от дължини на обучителен период (напр. 3, 10, 20 дни) и период на моделиране/валидация (30, 60, 90, 180 дни).



Фигура II-2 - Измерената ефективност на инвертора и дадената в техническите данни от производителя

Горната графика от Фигура. II-2 показва, ефективността на инвертор, изчислена от измерените данни за 7 дни, сравнена с ефективността, дадена от производителя.

Оценката е извършена с метрики MSD, MSE и относителна интегрална грешка на енергията.

Получените резултати показват, че:

- увеличаването на обучителния период не води непременно до висока точност, тъй като моделът е статистически и зависи от представителността („нормалността“) на дните в обучението;

- за по-дълги периоди на моделиране е възможно натрупване на систематично отклонение, което може да се намали чрез фина настройка на коефициентите или чрез периодично обновяване на β върху „плъзгащ прозорец“ от тренировъчни дни;

Обобщение: моделът на база мултилинейна регресия осигурява добра изчислителна ефективност и практическа приложимост за оценка/прогнозиране на инверторната ефективност и АС мощност, с възможност за адаптация към конкретна ФЕЦ чрез периодично обновяване на коефициентите.

II.3. Математическо моделиране на батерия във фотоволтаична електроцентрала

II.3.1. Мотивация и избран подход

За ФЕЦ със БЕСС адекватното моделиране на батерията е важно, както за анализ на експлоатационни режими и инвестиционни оценки, така и за бъдещи приложения, свързани с управление и планиране. Детерминистичните модели на батерии често изискват множество параметри (константи), които са специфични за конкретния тип батерия, изменят се с деградацията и трудно се идентифицират със „заден“ анализ върху исторически данни. Поради това е избран регресионен („black-box“) подход, който използва реални експлоатационни измервания и избягва необходимостта от детайлно параметризиране на електрохимичните процеси.

II.3.2. Регресионен модел на напрежението на батерията

Предложеният модел използва мултилинейна регресия, при която напрежението на батерията V_{bat} се моделира като функция на тока на батерията I_{bat} и състоянието на заряда SOC:

$$\text{II.3} \quad y_i = b_0 + b_1 x_{i1} + \dots + b_p x_{ip} + e_i = X_i^T + e_i$$

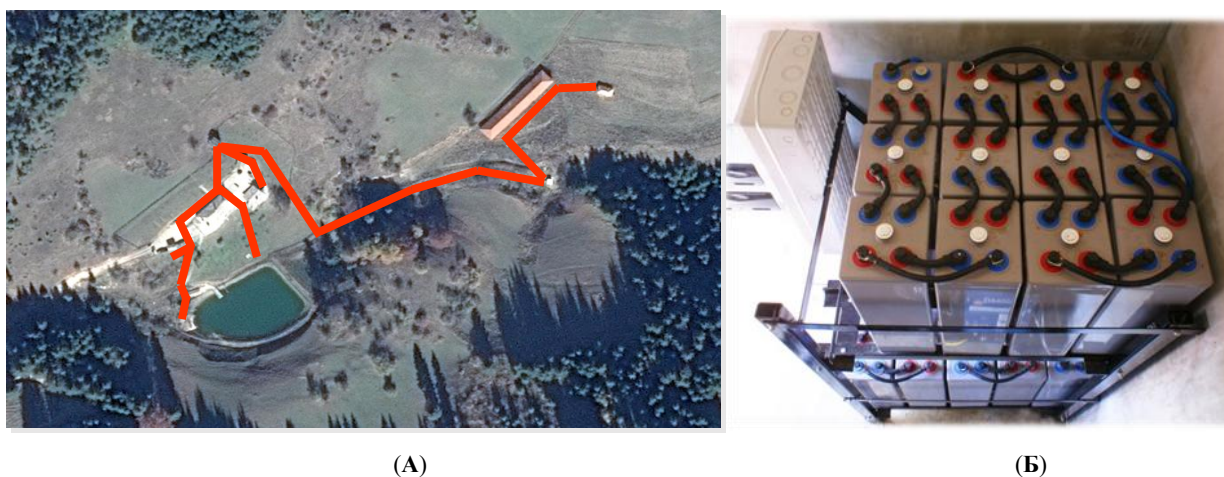
Коефициентите β се изчисляват от обучителен период, след което моделът се валидира върху следващ период по същата логика като при инвертора.

II.3.3. Данни и тестова система

За демонстрация и валидация са използвани данни от реална автономна микромрежа (жива лаборатория) към Лабораторията по устойчивост на електроенергийните системи (PSSL) на ТУ–София. Автономната микромрежа (Фиг. II.3 А) се състои от акумулаторна батерия 54 VDC, 43 kWh (Фигура II.3 Б), 8 kW двупосочен хибриден инвертор с възможност за

формиране и поддръжане на мрежа, един покривен ФВ генератор 2,3 kW и един фасаден ФВ генератор 2 kW, хидро генератор (HG) с мощност 3 kW и горен изравнител с вместимост 22kWh еднопосочно съхранение, основен (12kW) и спомагателен (4kW) дизел генератори (DG) и ~230V AC мрежа, която захранва няколко къщи, малък параклис и 5 други сгради в Родопи, България. Шината 54V DC се състои от 27 бр. батерии 2V, 800Ah OPzV.

Налични са измервания за 357 дни (01.01.2019–23.12.2019) с времева стъпка 1 минута (общо над 500 хил. записа).




Фигура II-3 (А) Изглед от лабораторна система в експлоатация. (Б) Батерийната система за съхранение на електрическа енергия.

Проведен е корелационен анализ, който показва осезаема зависимост между V_{bat} и избраните входни параметри, което обосновава избора на регресионния модел.

II.3.4. Валидация и изводи

Аналогично на модела на инвертора, са анализирани различни обучителни и валидационни периоди (кратки и по-дълги хоризонти).



Фигура П-4 - Изчислено и измерено напрежение на батерията, и разликата между двете променливи за трениращия период от 10 дни и периода на модела от 30 дни

Фигура.П-13 представя резултатите с изчисление с период на обучение от 10 дни. През този период няма изчислена променлива мощност и следователно няма разлика между моделираните и измерените параметри.

В Таблица П-1 са показани резултатите за различните тренировъчни и изчислителни период, както и стойностите на съответните коефициенти.

Таблица П-1 - Сравнителна таблица

№	Период от дни (и дни за трениране на модела)	Сравнителна таблица			
		β_1	β_2	β_3	MSE, kW ²
1	30 (3)	0,1340	58,1038	-0,0021	1,79
2	30 (10)	0,1171	58.6603	-0,0011	1,34
3	30 (20)	0,1047	58,6781	-0,0008	1,54
4	60 (3)	0,1340	58,1038	-0,0021	2,57
5	60 (10)	0,1171	58.6603	-0,0011	2,45
6	60 (20)	0,1047	58,6781	-0,0008	3,56
7	60 (20) – фина настройка	0,1061	58,6787	-0,0008	2,13
8	90 (3)	0,1340	58,1038	-0,0021	3.26
9	90 (10)	0,1171	58.6603	-0,0011	3,18
10	90 (20)	0,1047	58,6781	-0,0008	3,78
11	90 (20) – фина настройка	0,1061	58,6787	-0,0008	2,72
12	180 (3)	0,1340	58,1038	-0,0021	6,11
13	180 (10)	0,1171	58.6603	-0,0011	5,48
14	180 (20)	0,1047	58,6781	-0,0008	6,27
15	180 (20) – фина настройка	0,1061	58,6787	-0,0008	4,87

Резултатите показват, че:

- удължаването на обучителния период не гарантира по-ниска грешка при мултилинейна регресия, тъй като точността зависи от режима на заряд/разряд и представителността на включените дни;
- възможно е подобрене чрез фина настройка на коефициентите или чрез периодично преизчисляване, което поддържа коефициентите актуални спрямо текущото състояние на системата;
- при наличие на допълнителни измервания (напр. температура) моделът може да бъде разширен с нови независими променливи, когато термичните ефекти са значими.

Обобщение: регресионният модел предлага практично решение за моделиране на напрежението на батерията при реални режими, без необходимост от трудоемко определяне на специфични батерийни константи. Реализация и практичната форма на модела го правят приложим за различни системи и мащаби и подходящ за интегриране към модели на ФЕЦ.

ГЛАВА III МОДЕЛИРАНЕ НА ФОТОВОЛТАИЧНА ЕЛЕКТРОЦЕНТРАЛА И НЕЙНИ ЕЛЕМЕНТИ ЧРЕЗ МЕТОДИ ЗА МАШИННО ОБУЧЕНИЕ

III.1. Общ преглед и цел на главата

Глава III се състои от 3 последователни изследвания, а именно (1) моделиране и прогнозиране на производството на електроенергия от фотоволтаични електроцентрали (ФЕЦ), (2) моделиране на батерийни системи за съхранение на енергия (БССЕЕ), чрез прилагане на методи за машинно обучение (ML) и дълбоко обучение (DL), и (3) изследване за прогнозиране на производството на ФЕЦ чрез прогнозиране на слънчевата радиация с времеви редове.

Сред основните цели на главата е да се оцени приложимостта и точността на различни data-driven модели при реални експлоатационни условия и да се изследва влиянието на периода на обучение и оптимизацията на хиперпараметрите върху качеството на прогнозите.

III.2. Моделиране на производството на електроенергия от ФЕЦ чрез методи за машинно обучение

Надеждното моделиране и прогнозиране на производството на електроенергия от фотоволтаични електроцентрали е ключов фактор за тяхната ефективна интеграция в електроенергийните системи. Променливият

и стохастичен характер на слънчевата радиация води до значителни колебания в производството, което усложнява планирането, балансирането и управлението на електроенергийните ресурси.

Традиционните параметрични модели изискват детайлна информация за характеристиките на фотоволтаичните модули, инверторите и останалите компоненти на системата. На практика тази информация често е непълна, неточна или остаряваща във времето поради деградация и промени в експлоатационните условия. Това мотивира прилагането на методи за машинно обучение, които позволяват моделиране на поведението на ФЕЦ директно от измерени данни, без необходимост от детайлно физическо описание на системата.

В тази подчаст е избран подход, базиран на класически регресионни методи за машинно обучение, които са сравнително лесни за интерпретация, имат ниска изчислителна сложност и позволяват систематично сравнение на резултатите при различни конфигурации на входните параметри.

III.2.2. Методология, модели и реализация

Изследването е проведено с реални измерени данни от фотоволтаична електроцентрала с инсталирана мощност 103 kWp, разположена в България. Използваните входни параметри включват слънчева радиация, температура на околната среда, температура на фотоволтаичните модули и скорост на вятъра.

Данните са разделени на обучаващ, валидационен и тестов набор, като е приложено систематично търсене на оптимални хиперпараметри чрез gridsearch и кръстосана валидация. Разгледани са следните методи за машинно обучение:

- множествена линейна регресия;
- линейна регресия с полиномни характеристики;
- Ridge и Lasso регресия;
- дървета на решенията;
- Random Forest регресия.

Особено внимание е отделено на влиянието на полиномното разширяване на входните характеристики и на възможността за намаляване на броя на входните параметри, като се запази висока точност на прогнозиране. За оценка на резултатите са използвани коефициентът на детерминация R^2 , средноквадратичната грешка (RMSE) и нормализираната RMSE, нормализирана спрямо инсталираната мощност на електроцентралата.

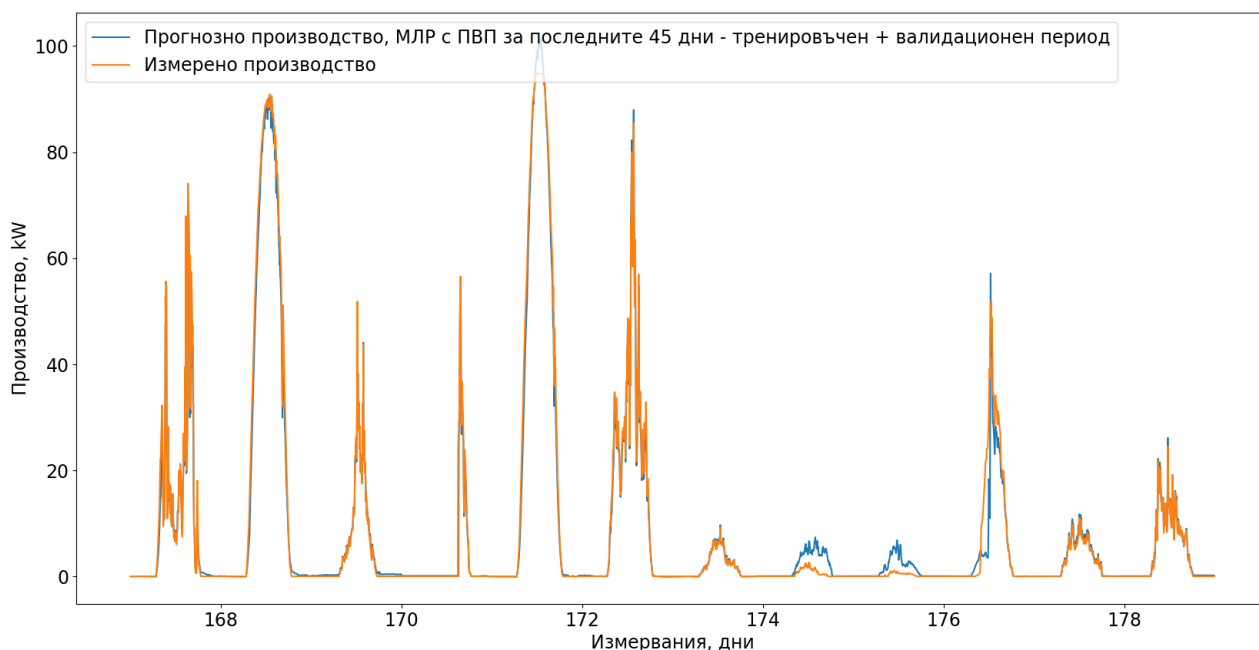
III.2.3. Валидация, резултати и изводи

Съобразно резултатите в Таблица III-1, избраният алгоритъм за изпитване върху набора от тестови данни е линейна регресия с полиномни параметри на 2-ра степен. Полученият R^2 на крайния набор от тестове е 0,87202. Това е по-нисък резултат от очакваното. Освен това, експериментите, ползващи алгоритъм за обучение на 60 дни + тестов набор (последните дни от измервания период), са по-високи – R^2 е равен на 0,98699 на тестовия набор, RMSE 1,76 kW, RMSE тестов период 2,27 kW и nRMSE 2,37%. Причината, поради която по-дългият период на тренировка описва по-малка част от тестовите данни, се дължи на сезонността – тегловните коефициенти на линейния модел се тренират на други входни параметри от друг сезон, и съответно различна околната температура, което води до отклонение (дрейф) на данните.

Таблица III-1 - Резултати от изчисленията на включените модели

ML methods	Results			
	R^2	RMSE (training + validation set), kW	RMSE (validation set), kW	nRMSE, %
Linear Regression	0,991953	3,48	2,89	3,01
LReg + poly features	0,993677	2,21	1,74	1,81
Lasso	0,993671	3,46	2,63	2,74
Ridge	0,993611	3,47	2,65	2,76
Decision Trees	0,988247	1,29	3,59	3,74
Random Forest	0,991906	1,57	2,98	3,11

Фигура.III-1 показва, че прогнозираните и измерените стойности почти се припокриват. Причината за това е, че периодът, за който температурният коефициент е определен като оптимален, е много по-близък във времето до периода на тестовото изпитване.



Фигура III-1 - Графика на прогнозираното производство за тестовия период, изчислена с МЛР модел с полиномни входни параметри от втора степен, трениран на последните 45 дни, сравнено с действителното измерено производство

Установено е, че използването на по-кратки периоди на обучение, близки във времето до прогнозирания период, води до по-добра обобщаваща способност на моделите. Това показва, че при практическо приложение е целесъобразно периодично или адаптивно повторно обучение на моделите.

Изводът от тази подточка е, че класическите регресионни методи за машинно обучение са напълно приложими за моделиране на производството на електроенергия от ФЕЦ и могат да постигнат висока точност дори при ограничен набор от входни параметри.

III.3. Моделиране на батерийни системи за съхранение на енергия чрез машинно и дълбоко обучение

III.3.1. Мотивация и избран подход

Интегрирането на батерийни системи за съхранение на енергия към фотоволтаични електроцентрали поставя допълнителни изисквания към моделирането и прогнозиране на поведението на тези системи. Напрежението на батерията, като ключов оперативен параметър, зависи от множество взаимосвързани фактори, включително ток, натоварване, температура и режим на работа.

Физическото моделиране на батерийните системи е сложно и често изисква детайлна информация за химията, вътрешните съпротивления и

деградационните процеси. Поради това в тази подчаст е избран подход, базиран на машинно и дълбоко обучение, който позволява моделиране на напрежението на батерията директно от измерени данни в реални експлоатационни условия.

III.3.2. Методология, модели и реализация

Изследването е проведено с реални данни от автономна микромрежа с интегрирана батерийна система, записвани с времева резолюция от една минута за период от една година. След предварителна обработка, нормализация и анализ на корелациите са избрани основните входни параметри, които имат най-силно влияние върху напрежението на батерията.

Разгледани са следните групи модели:


- множествена линейна регресия със и без полиномни характеристики;
- невронни мрежи с предварителна връзка (FNN);
- хомогенни ансамбли от FNN;
- модели, базирани на дървета на решенията – XGBoost, CatBoost и LightGBM;
- хетерогенни ансамблови модели, комбиниращи различни базови алгоритми.

Оптимизацията на хиперпараметрите на по-сложните модели е извършена чрез Байесова оптимизация. Въведена е и персонализирана функция за ранно спиране, която едновременно следи показателите за обучение и валидация и позволява редуциране на преобучаването.

Особен акцент е поставен върху изследването на оптималната продължителност на периода на обучение, като са сравнени периоди от 15, 30, 60 и 90 дни.

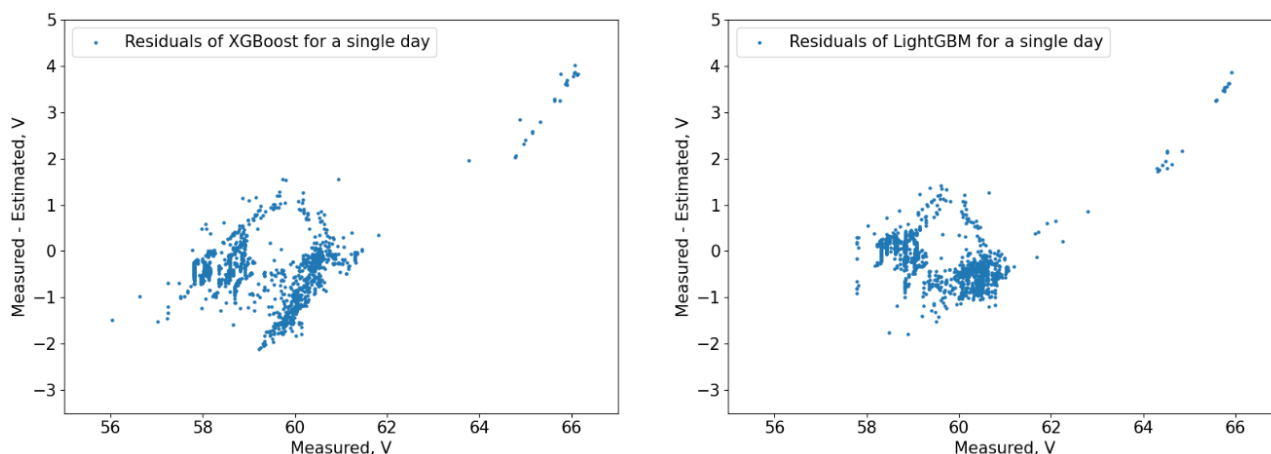
III.3.3. Валидация, резултати и изводи

Резултатите показват, че моделите, базирани на дървета на решенията, и по-специално CatBoost и хетерогенните ансамбли, постигат най-ниски стойности на нормализираната средноквадратична грешка. Установено е, че период на обучение от около 30 дни осигурява най-добър компромис между точност и устойчивост на прогнозата.



Фигура Error! No text of specified style in document.-2 - Измерено и прогнозирано напрежение на батерията, изчислено от модела XGBoost за модел на 15-дневен период на обучение

Фигури III-2 показва измереното и прогнозираното напрежение на батерията, изчислено от модела XGBoost за модел на 15-дневен период на обучение.



Фигура III-3 - Графики на грешки (residuals) за модели XGBoost и LightGBM за ден 212

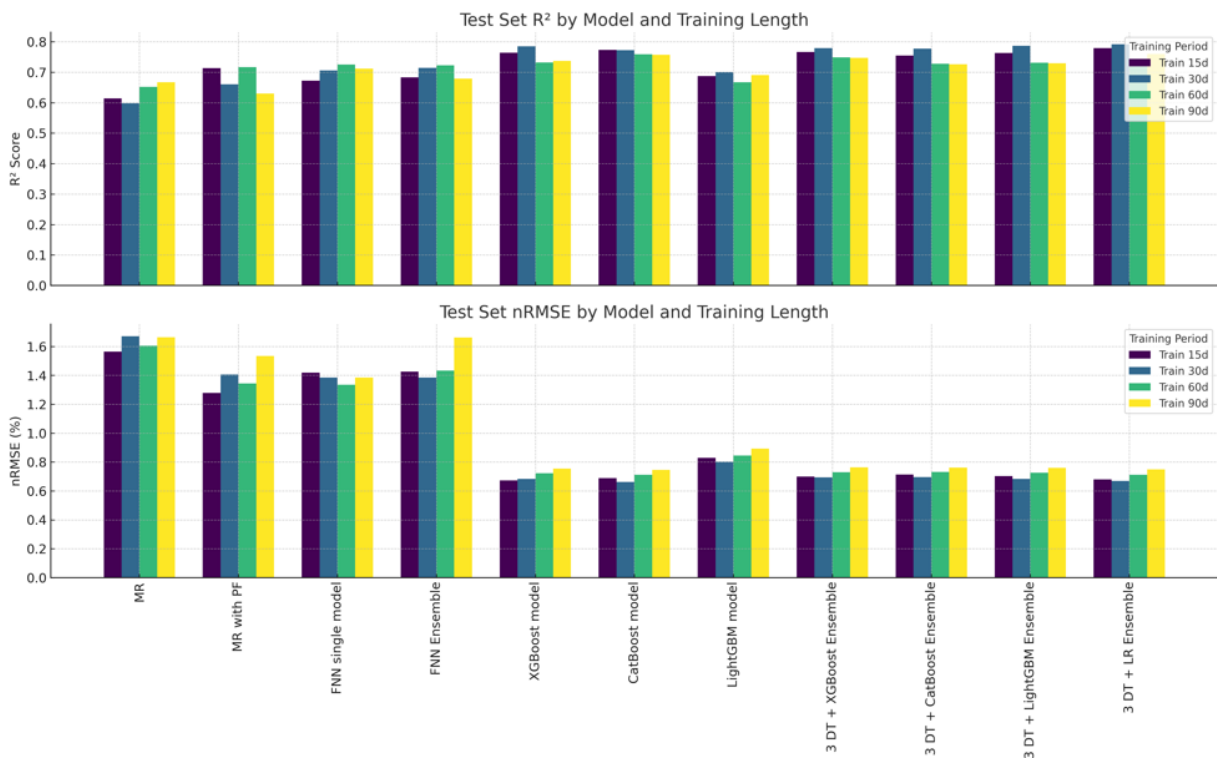
Изчислените грешки за отделните модели (на Фигура III-3 са изобразени за XGBoost и LightGBM за ден 212) показват, че моделите улавят различни зависимости между входните параметри и прогнозираната променлива.

Таблица III-2 – Резултати от трениращия, валидационния и тестовия сет данни

Модел тип	Период на трениране	Трен. R ²	Вал. R ²	Тестови R ²	nRMSE Трен., %	nRMSE Вал., %	nRMSE Тестови, %
МЛР	15	0,756	0,710	0,614	1,514	1,662	1,563
МЛР	30	0,734	0,645	0,598	1,618	1,818	1,670
МЛР	60	0,725	0,644	0,652	1,657	1,845	1,604

MLP	90	0,712	0,611	0,667	1,712	1,949	1,663
MLP с ПВП	15	0,884	0,805	0,713	1,025	1,292	1,278
MLP с ПВП	30	0,853	0,729	0,660	1,163	1,511	1,406
MLP с ПВП	60	0,809	0,705	0,717	1,340	1,585	1,344
MLP с ПВП	90	0,786	0,655	0,630	1,442	1,725	1,534
FNN единичен	15	0,876	0,902	0,672	1,550	1,396	1,418
FNN единичен	30	0,843	0,902	0,706	1,436	1,317	1,384
FNN единичен	60	0,810	0,884	0,725	1,448	1,385	1,334
FNN единичен	90	0,794	0,872	0,712	1,490	1,433	1,384
FNN ансамбъл	15	0,793	0,831	0,683	1,409	1,360	1,425
FNN ансамбъл	30	0,776	0,817	0,714	1,461	1,344	1,384
FNN ансамбъл	60	0,758	0,807	0,723	1,564	1,479	1,432
FNN ансамбъл	90	0,729	0,826	0,679	1,662	1,422	1,662
XGBoost	15	0,94	0,905	0,764	0,442	0,452	0,673
XGBoost	30	0,934	0,917	0,785	0,477	0,487	0,683
XGBoost	60	0,912	0,872	0,732	0,555	0,605	0,723
XGBoost	90	0,902	0,857	0,737	0,592	0,675	0,755
CatBoost	15	0,941	0,907	0,773	0,437	0,443	0,689
CatBoost	30	0,923	0,903	0,772	0,518	0,523	0,662
CatBoost	60	0,898	0,854	0,759	0,598	0,637	0,712
CatBoost	90	0,887	0,838	0,757	0,638	0,718	0,745
LightGBM	15	0,875	0,851	0,687	0,632	0,638	0,828
LightGBM	30	0,861	0,835	0,701	0,693	0,689	0,802
LightGBM	60	0,835	0,803	0,667	0,759	0,783	0,844
LightGBM модел	90	0,823	0,758	0,691	0,795	0,853	0,892
3 DT + XGBoost ансамбъл	15	0,944	0,929	0,766	0,421	0,428	0,699
3 DT + XGBoost ансамбъл	30	0,927	0,906	0,779	0,503	0,51	0,693
3 DT + XGBoost ансамбъл	60	0,902	0,858	0,749	0,586	0,627	0,73
3 DT + XGBoost ансамбъл	90	0,891	0,841	0,747	0,627	0,707	0,763
3 DT + CatBoost ансамбъл	15	0,957	0,949	0,755	0,364	0,361	0,713
3 DT + CatBoost	30	0,941	0,926	0,777	0,448	0,449	0,696

ансамбъл							
3 DT + CatBoost ансамбъл	60	0.917	0.88	0.728	0.538	0.569	0.732
3 DT + CatBoost ансамбъл	90	0.905	0.864	0.726	0.584	0.651	0.761
3 DT + LightGBM ансамбъл	15	0.95	0.937	0.763	0.395	0.402	0.702
3 DT + LightGBM ансамбъл	30	0.937	0.92	0.787	0.466	0.472	0.684
3 DT + LightGBM ансамбъл	60	0.916	0.877	0.731	0.542	0.578	0.726
3 DT + LightGBM ансамбъл	90	0.906	0.865	0.729	0.58	0.647	0.759
3 DT + LR ансамбъл	15	0.941	0.926	0.779	0.433	0.443	0.679
3 DT + LR ансамбъл	30	0.923	0.904	0.792	0.517	0.5232	0.669
3 DT + LR ансамбъл	60	0.898	0.852	0.741	0.601	0.648	0.711
3 DT + LR ансамбъл	90	0.886	0.836	0.76	0.640	0.726	0.749



Фигура III-4 - Представяне на резултатите на всички модели за R² и nRMSE за всеки тренировъчен период

Резултатите, представени в Таблица III-3, са показани в диаграма на Фигура III-4. Диаграмата показва всички модели в два реда. Първият ред показва резултатите за всеки модел за тестовия набор R^2 за всяка продължителност на обучението – 15, 30, 60 и 90 дни. Вторият ред показва резултатите за nRMSE на всеки модел.

Най-добрият резултат за 37-дневната средна грешка на nRMSE за тестовите данни е постигнат от модела CatBoost с 30-дневен период на обучение.

Най-високият резултат R^2 за тестовите данни на проучването е показан от хетерогенния 3 DT + LR ансамбъл, докато ансамбълът 3 DT + LightGBM следва плътно на второ място. Третият резултат е от модела XGBoost. Първите три резултата са в 30-дневния период на обучение.

Като цяло, моделите, почиващи на дърво на решенията, показват по-добри резултати в сравнение с FNN, ансамбъла от FNN и множествените регресионни модели със и без полиномиални характеристики.

Това може да предполага, че оптималният период на обучение за това проучване е 30 дни. Това означава, че по-дълги периоди на обучение не са необходими за постигане на оптимални резултати при прогнозиране.

Невронните мрежи с предварителна връзка и техните ансамбли постигат приемливи, но по-ниски резултати в сравнение с ансамбловите модели на дървета на решенията. Това показва, че за разглеждания тип данни и задача по-простите, но добре оптимизирани модели могат да бъдат по-ефективни от по-дълбоките архитектури.

Основният извод е, че подходите, базирани на машинно обучение, са приложими за моделиране на батерийни системи в реални условия и позволяват ефективно прогнозиране на напрежението без използване на детайлни физически модели.

III.4. Прогнозиране на производството на ФЕЦ чрез прогнозиране на слънчевата радиация с времеви редове

III.4.1. Мотивация и избран подход

Слънчевата радиация е основният фактор, определящ производството на електроенергия от фотоволтаичните електроцентрали. Следователно, подобряването на прогнозата за слънчевата радиация води пряко до подобряване на прогнозата за произведената електроенергия.

Краткосрочното прогнозиране ден напред представлява особено предизвикателство поради високата изменчивост на метеорологичните условия. Това мотивира използването на методи за анализ на времеви редове,

които могат да улавят както краткосрочни, така и дългосрочни зависимости в данните.

В тази подточка е избран сравнителен подход между класически модели за машинно обучение и съвременни архитектури на дълбоки невронни мрежи, специализирани за прогнозиране на времеви редове.

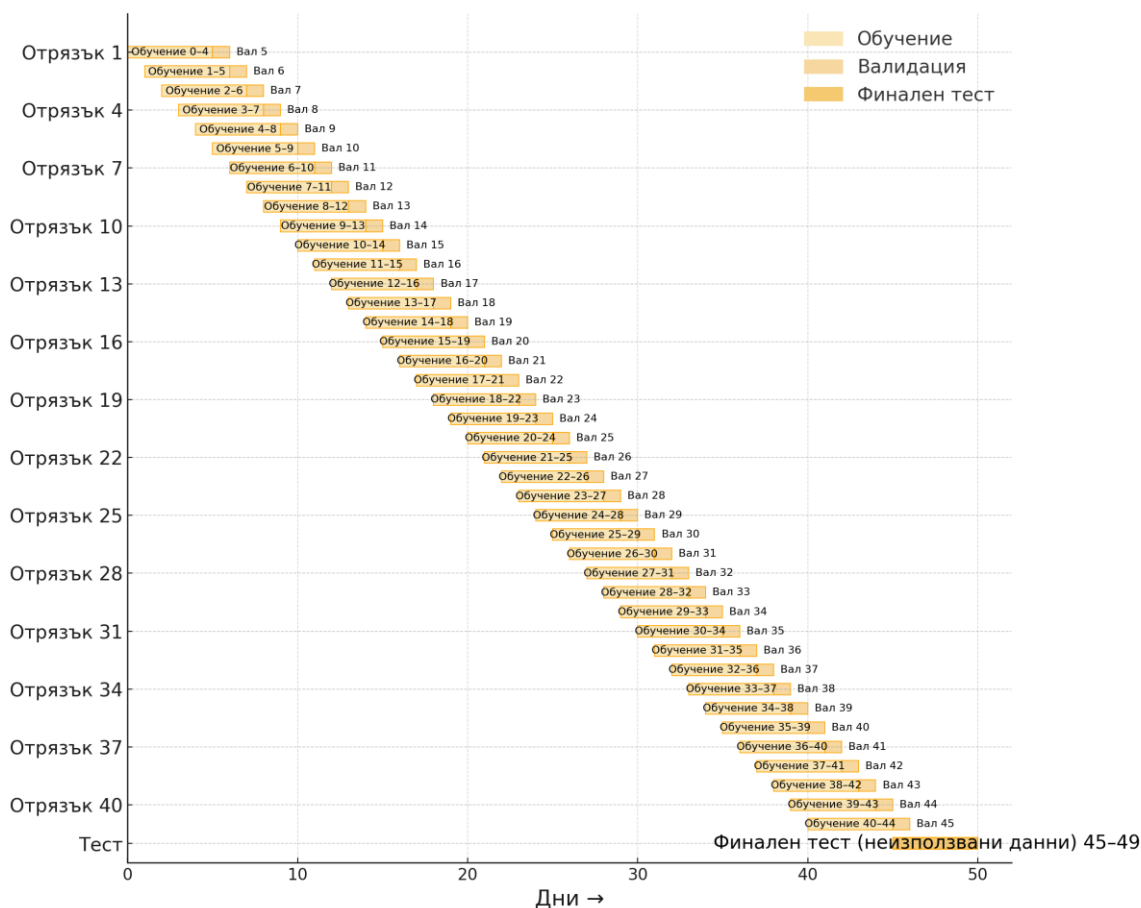
III.4.2. Методология, модели и реализация

Използвани са измерени данни за слънчева радиация и температура на околната среда от реална ФЕЦ, допълнени с външни метеорологични данни. Данните са агрегирани до часови стойности и обработени с помощта на трансформации, подходящи за анализ на времеви редове.

Разгледани са следните модели:

- XGBoost, CatBoost, LightGBM и Gradient Boosted Trees;
- Temporal Convolutional Networks (TCN);
- N-BEATS и N-HITS архитектури.


Плъзгаща валидация на времеви редове (5 дни обучение + 1 ден валидация) + Финален тест (45-50)




Фигура III-5 - Процес на плъзгаща се валидация на времеви серии (Rolling window Time series cross validation) – примерна графика

Процесът на обучение и валидация е реализиран чрез плъзгащ прозорец (rolling window), което осигурява реалистична оценка на представянето на моделите във времето. Оптимизацията на хиперпараметрите е извършена както чрез gridsearch, така и чрез автоматизирана Байесова оптимизация.

На Фигура III-5 е показан процес на плъзгаща се валидация на времеви серии (Rolling window Time series cross validation) – примерна графика, приложен в това изследване.



Фигура III-6 - Прогнозен и трениращи дни за 5 дневен период за ден 1 януари 2013, модел XGBoost



Фигура III-7 - Прогнозен и трениращи дни за 10 дневен период за ден 1 януари 2013, модел XGBoost

Фигура III-6 показва трениращите дни и прогнозния последен ден, за 5 дневен период за 1 януари 2013, модел XGBoost. Фигура III-7 показва трениращите дни и прогнозния последен ден, за 10 дневен период за 1 януари 2013, модел XGBoost.

III.3.3. Валидация, резултати и изводи

Резултатите показват ясно предимство на автоматизираната Байесова оптимизация спрямо класическото търсене в мрежа. Сред изследваните модели архитектурата N-HITS постига най-добър баланс между точност, стабилност и обобщаваща способност, като показва високи резултати по отношение на RMSE, nRMSE и процент дни с положителен R^2 . Също така, оптимизирането на хиперпараметрите чрез Байесова оптимизация, показва значително по-високи резултати от тренирането чрез GridSearch.

С най-нисък резултат за RMSE е моделът, базиран на GBT и трениран за 10 дни – 75.3 W/m². С най-висок среден резултат за всички дни от оптимизационния процес е моделът базиран на N-HITS и трениран за 5 дни – R^2 0.31. С най-висок среден резултат от само позитивните дни от оптимизационния период е CatBoost, трениран на 15 дни – 0.734 R^2 . С най-много дни с позитивен R^2 отново е моделът N-HITS, трениран с 5 дневен период.

Таблица III-4 - Резултати от оптимизирането чрез автоматизиран Байесова оптимизация

	№	Модел	Трен. период, дни	RMSE, W/m ²	nRMSE, %	R^2	R^2 от позит. дни	Дни с позит. резултат R^2	Прогнозирани дни в трен. период	Дни с позитивен R^2 , %
OPTUNA	1	XGBoost	5	82.5	7.4%	-0.844	0.675	165	202	81.7%
			10	78.2	7.0%	-2.671	0.690	165	197	83.8%
			15	78.1	7.0%	-4.198	0.711	155	192	80.7%
	2	CatBoost	5	78.4	7.0%	-0.581	0.710	165	202	81.7%
			10	75.5	6.8%	-3.085	0.694	168	197	85.3%
			15	75.5	6.8%	-4.525	0.734	153	192	79.7%
	3	LightGBM	5	77.9	7.0%	-1.334	0.717	157	202	77.7%
			10	76.9	6.9%	-3.645	0.698	157	197	79.7%
			15	80.0	7.2%	-4.431	0.719	144	192	75.0%
	4	GBT	5	78.7	7.1%	-0.928	0.710	162	202	80.2%
			10	75.3	6.8%	-4.310	0.732	158	197	80.2%
			15	75.7	6.8%	-4.252	0.723	152	192	79.2%
	5	N-BEATS	5	114.3	10.3%	-8.55	0.645	134	202	66.3%
			10	92.5	8.3%	-3.785	0.646	146	197	74.1%
			15	90.8	8.2%	-8.051	0.680	137	192	71.4%
	6	N-HITS	5	76.3	6.9%	0.31	0.695	177	202	87.6%
			10	77.6	7.0%	-0.084	0.647	173	197	87.8%
			15	76.8	6.9%	-0.126	0.677	163	192	84.9%
	7	TCN	5	108.3	9.7%	-2.84	0.596	140	202	69.3%
			10	104.2	9.4%	-5.051	0.637	134	197	68.0%
			15	104.4	9.4%	-5.682	0.650	126	192	65.6%

Изследванията върху отделен тестов набор потвърждават, че моделът N-HITS е способен да прогнозира слънчевата радиация ден напред с приемлива точност при реални условия.

Тестовия набор от данни се състои от 45 дни, от 1 април до 15 май 2013 година, които моделите не са „виждали“ до момента.

Те са подадени на изборния, на база показаните резултати и анализ, модел N-HITS. Тъй като показаните резултати от N-HITS за различните тренировъчни периоди са сравнително близки, макар и 5 дневния период да показва по-висок среден R^2 , от всички дни в оптимизационния процес, изчисления на тестовите данни са направени с 3-те периода за трениране – 5, 10 и 15 дни. Резултатите са показани в Таблица III-5.

Таблица III-5 - Резултати от тестовия набор данни със изборния модел

№	Модел	Трен. период, дни	RMSE, W/m ²	nRMSE, %	R^2	R^2 от позит. дни	Дни с позит. резултат R^2	Прогнозирани дни в трен.период	Дни с позитивен R^2 , %
TEST	N-HITS	5	108.9	9.8%	0.41	0.840	39	45	86.7%
		10	102.6	9.2%	0.647	0.786	43	45	95.6%
		15	104.1	9.4%	0.492	0.859	39	45	86.7%

Видно е, че 10 дневния период постига по-високи резултати на тестовия набор от данни спрямо 5 и 15 дни.

Изводът от тази подчаст е, че съвременните дълбоки архитектури за времеви редове са подходящи за краткосрочно прогнозиране на слънчевата радиация и могат ефективно да се използват като основа за прогнозиране на производството на електроенергия от ФЕЦ.

НАУЧНО-ПРИЛОЖНИ И ПРИЛОЖНИ ПРИНОСИ

1. Научно-приложни приноси

1. Предложен, реализиран и окачествен е структурен подход за изследване на режимите на работа на фотоволтаична електроцентрали и нейните компоненти посредством набор от детерминистични математически модели. Подходът позволява определяне на режимните параметри чрез представяне на отделните елементи, параметрите им и връзките между тях, пресъздавайки процесите и състоянията, свързани с тях.
2. Предложено е и е реализирано математическо моделиране на производството на електроенергия на фотоволтаични електрически централи чрез различни методи за машинно обучение, които не изискват експлицитното познаване на параметрите на елементите и

връзките между тях.

3. Направени са набор от изследвания, третиращи различни видове и топологии на фотоволтаични електрически централи с и без системи за съхранение на електрическа енергия, посредством различни методи и модификациите им, приложени за различни периоди на обучение. Проведен е сравнителен анализ на приложимостта, качествата и предимствата и недостатъците на отделните методи. Предложено е и е реализирано адаптивно определяне на периода на обучение като са обосновани ползите от този подход.

2. Приложни приноси

1. Разработени са софтуерни реализации, които позволяват осъществяване на целта и задачите на изследването по отношение на методите и средствата за моделиране на ФВЦ с цел изследване на режимите им.

СПИСЪК НА ПУБЛИКАЦИИТЕ ПО ДИСЕРТАЦИОННИЯ ТРУД

1. R. Stanev and T. Tanev, "Mathematical model of photovoltaic power plant," *2018 20th International Symposium on Electrical Apparatus and Technologies (SIELA)*, Bourgas, Bulgaria, 2018, pp. 1-4, doi: 10.1109/SIELA.2018.8447173. – 7 Citations
2. T. Ivanov and R. Stanev, "Mathematical model of photovoltaic inverters," *2019 11th Electrical Engineering Faculty Conference (BulEF)*, Varna, Bulgaria, 2019, pp. 1-5, doi: 10.1109/BulEF48056.2019.9030705.. – 8 Citations
3. T. Tanev and R. Stanev, "Mathematical Model of Battery Storage Installed in Photovoltaic Power Plant," *2020 21st International Symposium on Electrical Apparatus & Technologies (SIELA)*, Bourgas, Bulgaria, 2020, pp. 1-4, doi: 10.1109/SIELA49118.2020.9167155. – 2 Citations
4. T. Tanev and R. Stanev, "Artificial Intelligence RES Forecasting Based on Weather Data Time," *2021 13th Electrical Engineering Faculty Conference (BulEF)*, Varna, Bulgaria, 2021, pp. 1-6, doi: 10.1109/BulEF53491.2021.9690785. – 1 Citation
5. T. Tanev and R. Stanev, "Modeling of Photovoltaic Power Plant Electricity Generation Using Machine Learning Methods," *2021 17th Conference on Electrical Machines, Drives and Power Systems (ELMA)*, Sofia, Bulgaria, 2021, pp. 1-6, doi: 10.1109/ELMA52514.2021.9503066. - 2 Citations
6. Stanev, R.; Tanev, T.; Efthymiou, V.; Charalambous, C. Modeling of Battery Storage of Photovoltaic Power Plants Using Machine Learning Methods. *Energies* 2025, 18, 3210. <https://doi.org/10.3390/en18123210> - 1 Citation



TECHNICAL UNIVERSITY OF SOFIA
Faculty of Electrical Engineering
Department of Electrical Power Engineering

Tanyo Ivanov Tanev, Ms.C.

Study of the operating regimes of Photovoltaic power plants

SUMMARY

Dissertation title: Study of Operating Regimes of Photovoltaic Power Plants

Author: Eng. Tanyo Tanev MSc

The increasing penetration of photovoltaic power plants into modern power systems creates challenges related to the variability and uncertainty of electricity generation. Reliable modeling and forecasting of photovoltaic power production are therefore essential for efficient operation, planning, and integration of renewable energy sources, as well as for the operation of battery energy storage systems integrated into photovoltaic installations.

A review of the scientific literature shows that numerous mathematical and data-driven approaches have been proposed for modeling and forecasting. Classical mathematical models provide a physically meaningful description of photovoltaic power plants and their main components but often rely on deterministic parameters that are difficult to identify for each individual installation. Among the aims of the dissertation is to investigate a progressive modeling approach for the analysis and forecasting of photovoltaic power plant electricity generation. The research begins with classical mathematical modeling of the main components of photovoltaic power plants to establish a physically consistent baseline. Subsequently, the systems are treated as black-box objects, and machine learning and deep learning methods are applied to improve practical applicability. The focus is on evaluating the accuracy of the applied modeling approaches using real operational data. To achieve this, the following main tasks are accomplished:

1. Analysis of contemporary approaches for modeling and forecasting photovoltaic power generation using ML and DL methods.
2. Development and validation of mathematical models of photovoltaic power plants.
3. Modeling and analysis of battery energy storage systems.
4. Application and comparison of ML models for forecasting photovoltaic power generation based on historical environmental data.
5. Investigation of short-term (day-ahead) forecasting of photovoltaic power generation through time series modeling of solar irradiance.

6. Systematic optimization of model hyperparameters and evaluation of model performance using rolling time-series cross-validation under real operating conditions. Evaluation of the length of the training period influence.

The hyperparameter optimization and rolling time-series validation improve model performance. The proposed methodology confirms that the ML techniques can achieve high results and applicability for engineering analysis and forecasting.