



РОБОТА

на здобуття премії Президента України для молодих вчених

МОДЕЛІ ТА ЗАСОБИ КЕРУВАННЯ ЗАРЯДНИМИ СТАНЦІЯМИ ЕЛЕКТРОТРАНСПОРТУ В МІКРОМЕРЕЖІ ІЗ СОНЯЧНОЮ ГЕНЕРАЦІЄЮ

Представлено Інститутом загальної енергетики Національної академії наук України

Автори роботи:

Босак Андрій Васильович – доктор філософії, молодший науковий співробітник відділу прогнозування розвитку електроенергетичного комплексу Інституту загальної енергетики НАН України

Матушкін Дмитро Сергійович – доктор філософії, молодший науковий співробітник відділу прогнозування енергетичної ефективності та перспективних паливно-енергетичних балансів Інституту загальної енергетики НАН України



Інтеграція електротранспорту в мікромережі із сонячною генерацією супроводжується викликами пов'язаних із варіативністю сонячного випромінювання, балансуванням навантажень та оптимізацією розподілу енергії між споживачами в умовах обмеженого електропостачання.

Актуальність – необхідність розроблення моделей та засобів керування зарядними станціями електротранспорту, які враховують прогнозовану потужність сонячної електростанції. Використання прогнозних даних дозволяє не лише підвищити стабільність роботи мікромережі, а й оптимізувати процес заряджання електротранспорту, забезпечуючи більш раціональне використання доступної енергії.

Мета – підвищення ефективності управління зарядними станціями електротранспорту в мікромережах із сонячною генерацією шляхом розроблення моделей прогнозування генерації та алгоритмів інтелектуального керування зарядним процесом.

Для досягнення мети передбачається:

- розроблення моделей прогнозування сонячної генерації з урахуванням змінних метеорологічних умов та сезонних коливань;
- створення адаптивних стратегій розподілу енергії між зарядними станціями для підвищення стабільності мікромережі;
- впровадження алгоритмів нечіткого керування зарядними станціями з метою оптимізації енергоспоживання та зменшення навантаження на електричну мережу.

Розробка та впровадження ефективних моделей прогнозування сонячної генерації та оптимального керування зарядними станціями електротранспорту в мікромережі із сонячною генерацією.

Запропоновано використання адаптивних алгоритмів прогнозування (SARIMA, LSTM, Випадковий Ліс) для підвищення точності оцінки доступної енергії, що дозволяє ефективніше балансувати споживання електроенергії.


Розроблено алгоритм вагового індексу заряджання на основі нечіткої логіки, що дає змогу адаптивно керувати процесом заряджання електротранспорту залежно від рівня заряду акумулятора, попиту та наявної потужності у мікромережі.

Дослідження довело, що інтеграція точного прогнозування та інтелектуального керування зарядними станціями дозволяє мінімізувати небаланси енергії, зменшити пікові навантаження на мережу та підвищити ефективність використання відновлюваних джерел енергії.

Сонячна електростанція



Система зберігання енергії



Підвищувальний перетворювач



Шина постійного струму



Інвертор



Перетворювач



Електромережа



Навантаження змінного струму



Стохастичні процеси

НЕБАЛАНСИ В ЕНЕРГОСИСТЕМІ

Детерміновані процеси

- похибки прогнозування генерації та навантаження;
- непередбачувані відключення електростанцій;
- похибки у прогнозуванні ВДЕ-генерації

- стрибки графіків генерації та навантаження;
- відхилення електричних параметрів мережі (напруга, струм і т. д.)



1. Вперше розроблено оптимізаційну модель керування зарядними станціями електротранспорту в реальному часі, що дозволяє більш ефективно розподіляти енергію для зарядки акумуляторів електромобілів при однакових обмеженнях споживання в місці підключення зарядних станцій, забезпечуючи максимальну ефективність використання енергетичних ресурсів.
2. Вперше розроблено методику експертної системи пріоритетності заряджання на основі нечіткої логіки, що дозволяє оптимізувати процес керування зарядними станціями в умовах обмеженого електропостачання, забезпечуючи необхідні рівні зарядки для електромобілів з урахуванням факторів, таких як поточне навантаження на мережу, прогноз генерації сонячної енергії та індивідуальні потреби користувачів.
3. Вперше розроблено імітаційну модель і проведено моделювання процесу керованої зарядки електротранспорту в умовах обмеженого електропостачання в середовищі MATLAB&Simulink, що дозволило виявити, що запропонований метод оптимального розподілу зарядної потужності між електромобілями з урахуванням обмежень мережі та індивідуальних потреб забезпечує підвищену стабільність і ефективність роботи мікромережі з сонячною генерацією.
4. Розроблено механізм урахування змінних метеорологічних умов та сезонних коливань при прогнозуванні генерації сонячної енергії, що дозволяє адаптувати стратегії керування зарядними станціями електротранспорту до динамічних змін доступної потужності сонячної генерації, підвищуючи точність розподілу енергетичних ресурсів в мікромережах з урахуванням зовнішніх факторів.
5. Розвинуто моделі прогнозування генерації сонячної енергії, використовуючи експоненційне згладжування, регресійний аналіз та штучні нейронні мережі, що дозволяє значно підвищити точність прогнозів і забезпечити більш ефективне керування зарядними станціями в мікромережах із сонячною генерацією.



Класична простого експоненційного згладжування модель (МПЕЗ-1) поєднує фактичні дані сонячної генерації з прогнозами попереднього періоду, що дає змогу оперативно реагувати на зміни сонячного випромінювання та адаптувати прогноз до його варіабельності. Завдяки цьому підходу модель здатна враховувати найсвіжішу інформацію.

Новий прогноз визначається як комбінація останнього виміряного значення генерації та попереднього прогнозу з урахуванням відповідних вагових коефіцієнтів.

Математичне представлення МПЕЗ-1 наступне:

$$\hat{P}_{t+1} = \alpha P_t + (1 - \alpha) \hat{P}_t$$

\hat{P}_{t+1} – прогнозне значення генерації СЕС у момент часу $t+1$; P_t – фактичне значення генерації в момент часу t ; \hat{P}_t – прогнозне значення генерації в момент часу t ; α – ваговий коефіцієнт згладжування ($0 \leq \alpha \leq 1$), що визначає вагу фактичного значення генерації у прогнозі.

Коефіцієнт згладжування α впливає на чутливість прогнозу до останніх спостережень.


Модель простого експоненційного згладжування відзначається високою адаптивністю та низькими обчислювальними витратами. Проте її точність кардинально знижується через добову циклічність сонячного випромінювання, оскільки чергування активної генерації вдень та нульових значень уночі спричиняє значні похибки. Це особливо актуально за змінних метеорологічних умов.

Для підвищення точності прогнозування в умовах мікромережі запропоновано модифікований підхід – модель МПЕЗ-2. На відміну від МПЕЗ-1, вона враховує не лише останні фактичні значення поточного дня, а й прогнозні дані попередньої доби за той самий часовий інтервал. Це дозволяє ефективніше адаптувати прогноз до повторюваних закономірностей сонячного циклу, що сприяє зменшенню похибок.

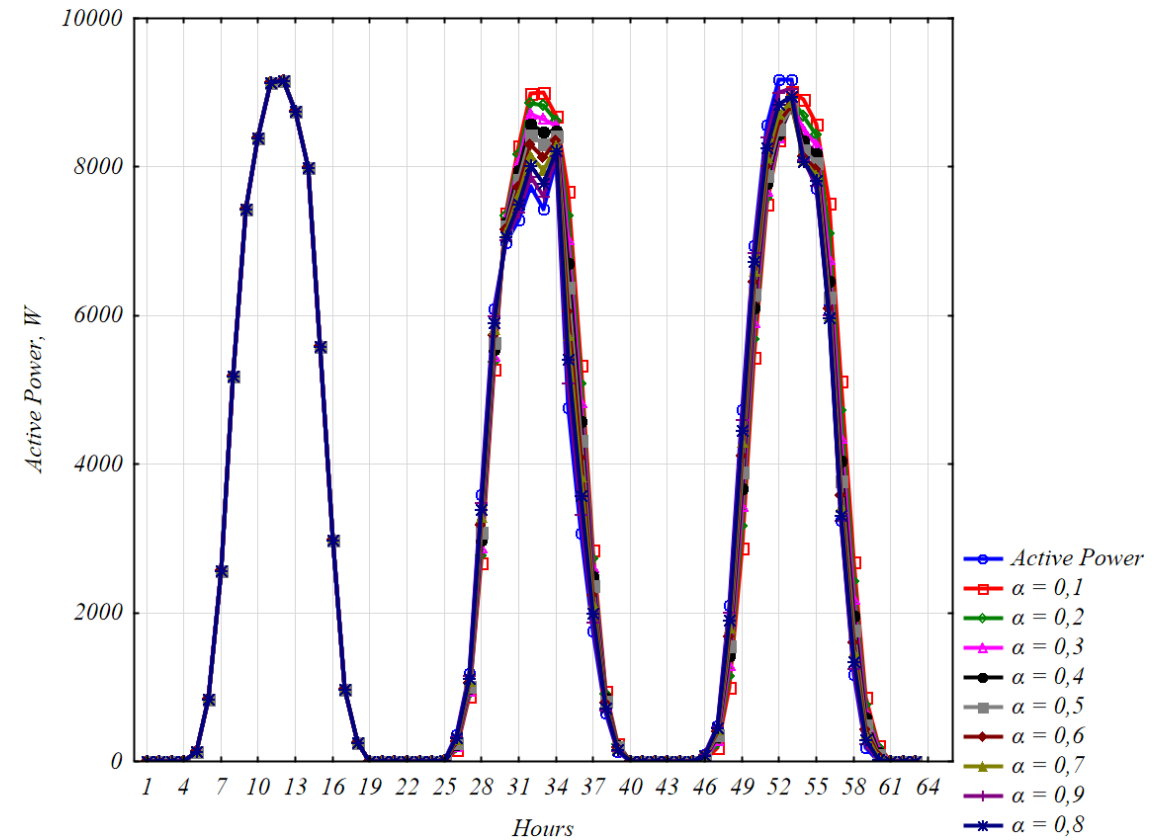
Математичне представлення МПЕЗ-2 наступне:

$$\hat{P}_t^d = \alpha P_t^d + (1 - \alpha) \hat{P}_t^{d-1}$$

\hat{P}_t^d – прогнозне значення генерації СЕС у момент часу $t+1$; P_t^d – фактичне значення генерації в момент часу t ; \hat{P}_t^{d-1} – прогнозне значення генерації в момент часу t ; α – ваговий коефіцієнт згладжування ($0 \leq \alpha \leq 1$), що визначає вагу фактичного значення генерації у прогнозі.



а)



б)

Прогнозування генерації СЕС при різних значеннях параметра: а) МПЕЗ-1; б) МПЕЗ-2

Прогнози генерації СЕС, отримані за допомогою цих моделей, підтверджують відмінності між їхньою ефективністю. Для МПЕЗ-1 спостерігалися значні відхилення між прогнозованими та фактичними значеннями. У випадку МПЕЗ-2 такі відхилення мінімальні, а її прогнозовані значення майже повністю збігаються з фактичними. Це робить МПЕЗ-2 більш надійною та точною для прогнозування генерації СЕС, особливо при високих значеннях параметра згладжування.



Модель SARIMA є розширенням стандартної моделі ARIMA, що дозволяє враховувати сезонні коливання у часових рядах. Вона ефективно використовується для прогнозування процесів із вираженою періодичністю, зокрема для сонячної генерації, де спостерігаються добові та річні цикли. Основна особливість SARIMA – включення сезонних компонентів, які дозволяють коригувати прогноз відповідно до повторюваних закономірностей.

Загальний вигляд моделі SARIMA можна представити як:

$$\text{SARIMA}(p, d, q) \times (P, D, Q)_s$$

де (p, d, q) – параметри несезонної моделі ARIMA, що включають авторегресійну частину, інтеграційну складову та компонент рухомого середнього відповідно; (P, D, Q) – параметри сезонної моделі ARIMA; s – періодичність часового ряду.

Математично модель SARIMA з урахуванням основних впливів випадкових похибок записується як:

$$\begin{cases} \phi(B)\nabla^d X_t = \Theta(B)\varepsilon_t, \\ E(\varepsilon_t) = 0, \text{Var}(\varepsilon_t) = \sigma^2, E(\varepsilon_t \varepsilon_s) = 0, s \neq t, \\ E(X_t, \varepsilon_s) = 0, \forall s < t \end{cases}$$

$\nabla^d = (1 - B)^d$ – оператор затримки; $\nabla^d X_t$ – часовий ряд після різниці кінцевого порядку; ε_t – послідовність білого шуму; $\Theta(B)$ – стабільний і оборотний поліном рухомого коефіцієнта згладжування моделі ARMA (p, q); $\phi(B)$ – поліном коефіцієнта авторегресії стаціонарної та оборотної моделей ARMA (p, q).

Авторегресійна частина моделі SARIMA, яка описує залежність поточного значення генерації від попередніх значень:

$$\hat{P}_{t+1} = \sum_{k=1}^p \alpha_k \hat{P}_{t+1-k} + \varepsilon_t$$

\hat{P}_{t+1} – прогнозне значення генерації на період $t+1$;

\hat{P}_{t+1-k} – попереднє прогнозне значення генерації.

Частина рухомого середнього моделі SARIMA, яка описує залежність поточного значення генерації від попередніх похибок:

$$P_t = \sum_{k=1}^q \Theta_k(B^q) \varepsilon_t$$

Загальний вираз моделі SARIMA:

$$\nabla^d \nabla_s^D P_t = \frac{\Theta(B)\Theta_s(B)}{\phi(B)\phi_s(B)} \varepsilon_t,$$

$$\phi_s(B) = 1 + \varphi_1 B^s + \dots + \varphi_p B^{ps}, \quad \Theta(B) = 1 + \theta_1 B + \dots + \theta_q B^q, \\ \Theta_s(B) = 1 + \theta_1 B^s + \dots + \theta_p B^{qs}.$$

Прогнозне значення за моделлю SARIMA:

$$\hat{P}_{t+1} = c + \sum_{i=1}^p \phi_i P_{t-i} + \sum_{k=1}^q \theta_k \varepsilon_{t-k} + \sum_{j=1}^P \Phi_j P_{t-sj} + \sum_{l=1}^Q \Theta_l \varepsilon_{t-sl} + \varepsilon_t$$



Вибір оптимальної моделі для прогнозування:

Правильний вибір моделі є ключовим для забезпечення високої точності прогнозування. Оптимальна структура SARIMA визначається шляхом аналізу таких статистичних показників:

✓ **Інформаційний критерій Акаїке (AIC):**

$$AIC = 2k - 2 \ln(L)$$

L – максимальне значення, отримане за допомогою функції оцінки максимальної правдоподібності, k – кількість оцінених параметрів.

Мінімальне значення AIC вказує на найкращу модель.

✓ **Залишкова сума квадратів** – оцінює різницю між фактичними та прогнозованими значеннями.

У результаті аналізу оптимальною виявилась модель SARIMA(1,0,1) × (2,1,0,24), яка показала найнижче значення AIC = 12826,840.

Результати показують, що модель SARIMA(1,0,1) × (2,1,0,24) демонструє кращі характеристики, ніж SARIMA(1,1,2) × (2,1,2,24). Вона забезпечує більш високий коефіцієнт детермінації між фактичними та прогнозованими значеннями ($R^2 = 0,92$), а також має нижче значення середньої абсолютної похибки (MAE = 258,57 кВт).

Комбінації параметрів моделі SARIMA



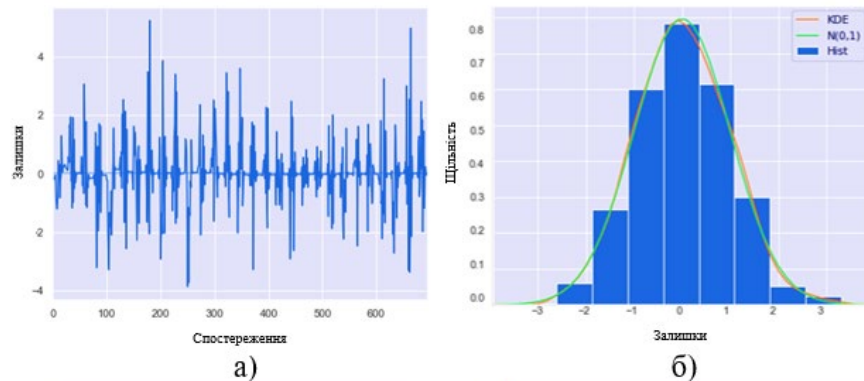
Комбінації ARIMA (p, d, q)	Сезонні параметри (P, D, Q, S)
(0, 0, 0)	(0, 0, 0, 24)
(0, 0, 1)	(0, 0, 1, 24)
(0, 1, 0)	(0, 1, 0, 24)
(0, 1, 1)	(0, 1, 1, 24)
(1, 0, 0)	(1, 0, 0, 24)
.....

Комбінації параметрів моделі SARIMA зі значеннями AIC


Комбінації ARIMA (p, d, q)	Сезонні параметри (P, D, Q, S)	AIC
(0, 0, 0)	(2, 1, 0, 24)	13105
(2, 0, 0)	(1, 1, 0, 24)	12954
(0, 0, 0)	(0, 1, 0, 24)	13388
(1, 0, 1)	(2, 1, 0, 24)	12826
(0, 0, 0)	(2, 1, 0, 24)	13104
.....

Порівняння метрик точності для отриманих результатів прогнозу для двох оптимальних моделей

Модель	MAE, кВт	RMSE, кВт	R ²
SARIMA(1, 1, 2) × (2, 1, 2, 24)	315,12	1245	0,87
SARIMA(1, 0, 1) × (2, 1, 0, 24)	258,57	1259	0,92



Модель SARIMA(1,1,2) × (2,1,2,24)



Модель SARIMA(1,0,1) × (2,1,0,24)

Аналіз залишкових похибок моделі SARIMA(1, 0, 1) × (2, 1, 0, 24):
а) стандартизований залишок; б) гістограма і щільність розподілу; в) нормальний Q-Q графік; г) корелограма залишків



Для прогнозування сонячної генерації було розглянуто кілька регресійних підходів: лінійна регресія, регуляризовані моделі (рідж-регресія та ласо-регресія) та ансамблевий метод випадкового лісу.

Лінійна регресія передбачає лінійну залежність між вихідною потужністю СЕС та вхідними метеорологічними факторами:

$$P^{Pred} = \beta_0 + \sum_{i=1}^n \beta_i X_i + \varepsilon$$

P^{Pred} – прогнозована потужність; X_1, \dots, X_i – метеорологічні чинники; β_1, \dots, β_i – константа регресії; β_0 – коефіцієнти регресії, що визначають вплив кожного чинника; ε – залишок моделі (залишкові похибки прогнозування).

Проте цей підхід має недолік – можливу багатоколінеарність, що знижує точність прогнозу. Щоб усунути цю проблему, застосовуються регуляризовані моделі.

Рідж-регресія (L2-регуляризація) додає штраф за занадто великі коефіцієнти, що запобігає перенавчанню:

$$Ridge_{loss} = \underbrace{\sum_{i=1}^N (P_i^{Obs} - P_i^{Pred})^2}_{\text{Залишок}} + \lambda \underbrace{\sum_{i=1}^k \beta_i^2}_{\text{Штраф}} \rightarrow \min$$

P_i^{Obs} – фактичне значення генерації; P_i^{Pred} – прогнозоване значення генерації; λ – параметр регуляризації, що контролює величину штрафу; β_i – ваги моделі.

Ласо-регресія (L1-регуляризація) автоматично відбирає найбільш значущі ознаки, зануляючи неінформативні коефіцієнти, що зменшує складність моделі:

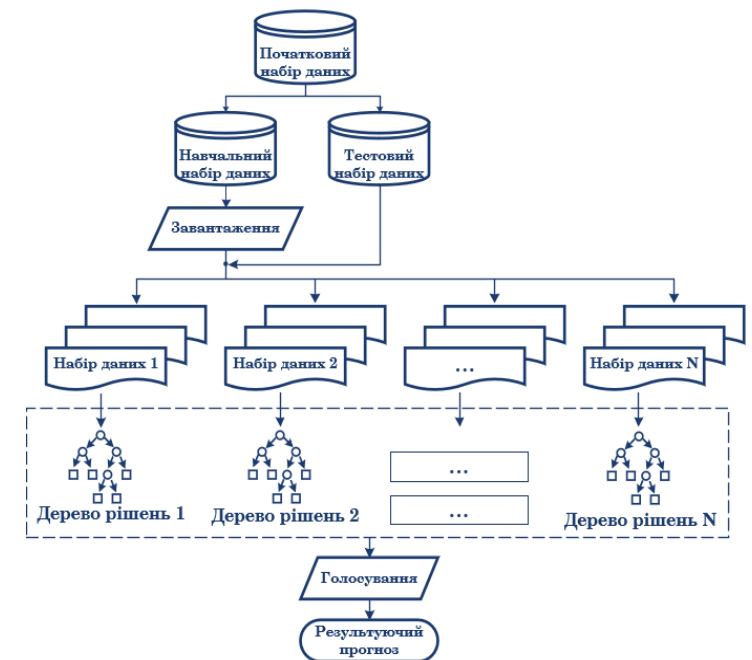
$$Lasso_{loss} = \underbrace{\sum_{i=1}^n (P_i^{Obs} - P_i^{Pred})^2}_{\text{Залишок}} + \lambda \underbrace{\sum_{j=1}^k |\beta_j|}_{\text{Штраф}} \rightarrow \min$$

Ансамблева модель випадкового лісу використовує набір дерев рішень, кожне з яких аналізує частину вибірки. Остаточний прогноз формується як середнє значення прогнозів усіх дерев. Ця модель добре враховує нелінійні залежності між змінними та забезпечує високу точність прогнозу.


$$P^{Pred} = \frac{1}{N} \sum_{i=1}^N P_i(x)$$

де Y_i – результуючий прогноз i -го дерева;

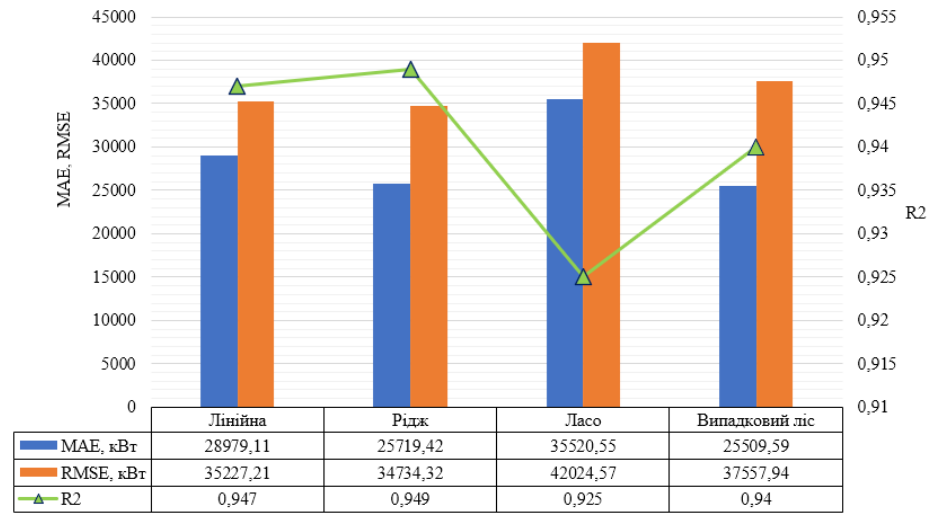
N – кількість дерев рішень у лісі.



Структура моделі випадкового лісу




а)




б)

Діаграми розподілу метрик MAE, RMSE та R², враховуючи сонячне випромінювання: а) на 10-ти хвилинному інтервалі, б) на щоденному інтервалі



а)




б)


Діаграми розподілу метрик MAE, RMSE та R², виключаючи сонячне випромінювання на 10-ти хвилинних інтервалах і враховуючи тривалість світлового дня на щоденних інтервалах: а) на 10-ти хвилинному інтервалі, б) на щоденному інтервалі



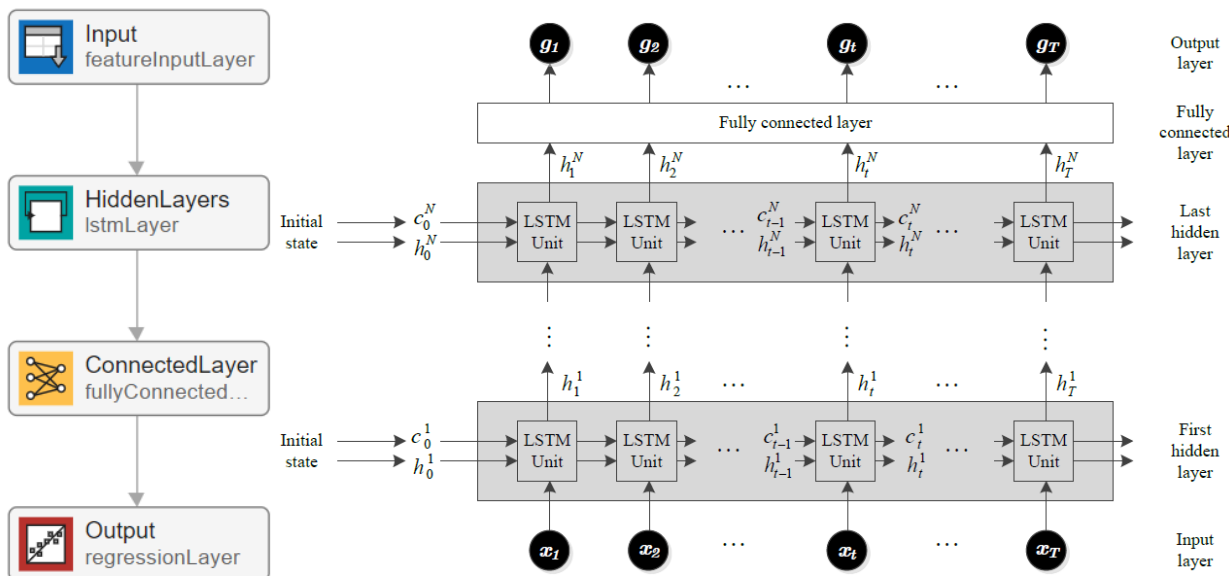
Найкращі результати серед розглянутих регресійних моделей продемонструвала **модель випадкового лісу**, яка забезпечила високу точність прогнозування на 10-хвилинних інтервалах та може бути адаптована для прогнозування на період, довший за добу.



Прогноз генерації за допомогою моделі випадкового лісу



Шари мережі LSTM



а)

б)

Архітектура моделі глибокого навчання:

а) Архітектура LSTM-шарів: h позначає виходи, c – стан комірки, N – кількість шарів;

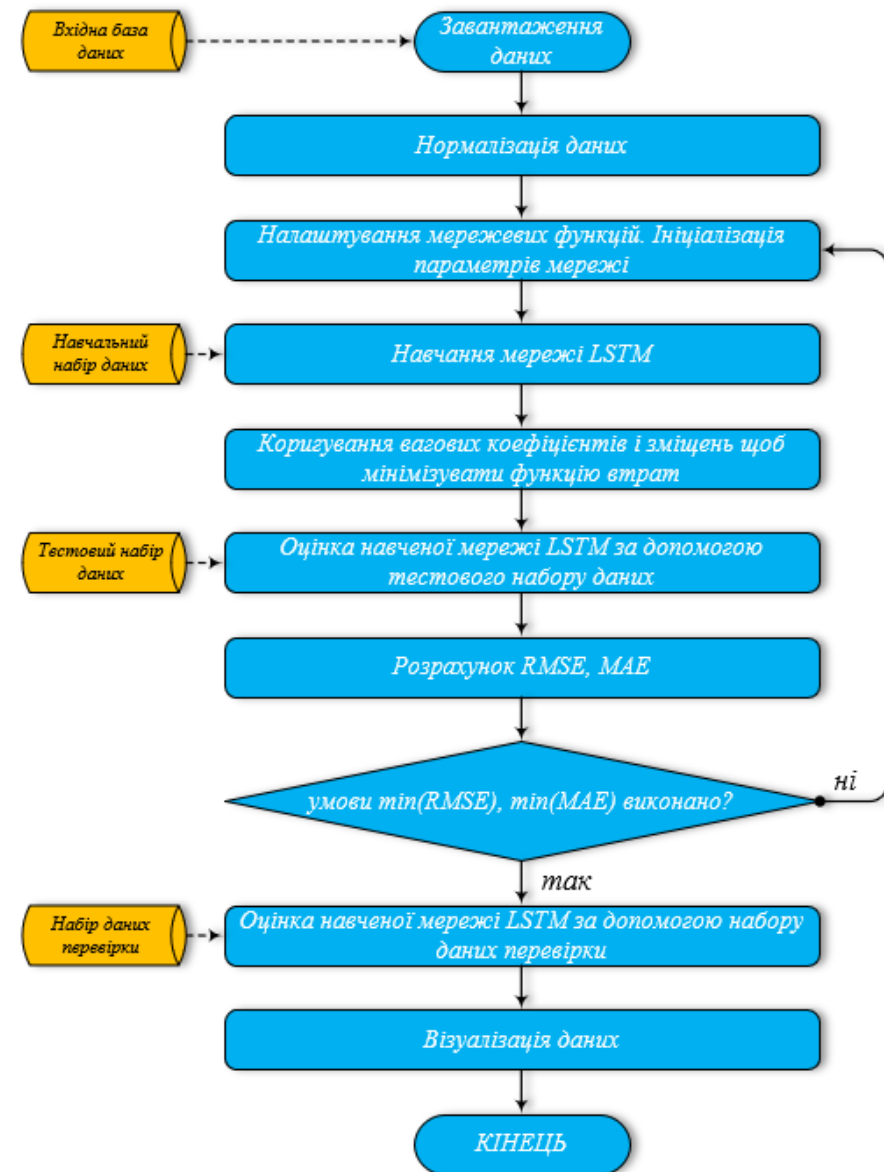
б) Конфігурація у додатку Deep Learning Toolbox у MATLAB&Simulink




Етапи розробки моделі LSTM




Етапи обробки даних



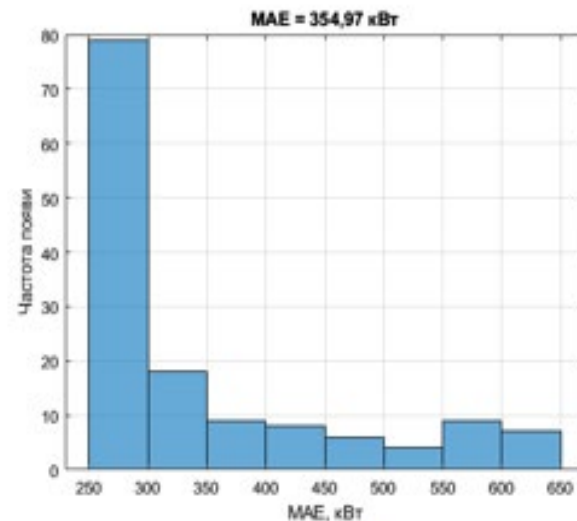
Блок-схема алгоритму розроблення моделі LSTM



Динаміка навчання моделі




а) Гістограми розподілу похибок: а) RMSE, б) MAE



б)

Оптимізовані параметри для навчання LSTM

Навчальні параметри	Значення
Початкова швидкість навчання	0,005
Вирішувач оптимізації	adam
Розклад швидкості навчання	piecewise
Коефіцієнт зниження швидкості навчання	0,5
Період зниження швидкості навчання	125
Розмір міні-партії	128
Масштабування функції	Standard
Кількість шарів	3
Приховані одиниці/шар	300
Кількість епох	300




Порівняння спостережуваної та прогнозованої потужності за моделлю LSTM




Узагальнення метрик точності розроблених моделей

Модель	RMSE	MAE	R^2	SS_{RMSE}	SS_{MAE}	Основні переваги	Основні недоліки
МПЕЗ-2	97,7	63,5	0,99	0,951	0,968	Простота реалізації, швидка обробка даних, низькі обчислювальні ресурси	Не враховує сезонність і динаміку зміни погодних умов
SARIMA	258,57	1259	0,92	0,368	0,870	Враховує сезонні коливання, помірна точність	Складне налаштування, потребує значного часу на оптимізацію
Випадковий ліс	1362,17	735,5	0,61	0,316	0,631	Добре працює з великими даними, враховує взаємозв'язки параметрів	Потребує значного обсягу даних, чутлива до вибору навчальних параметрів
LSTM	452,56	354,97	0,97	0,773	0,822	Висока точність, враховує довготривалі залежності, стійкість до шуму	Висока обчислювальна складність, тривалий час навчання



Розподіл метрик RMSE, MAE, R^2



Розподіл оцінок бенчмаркінгу прогнозів

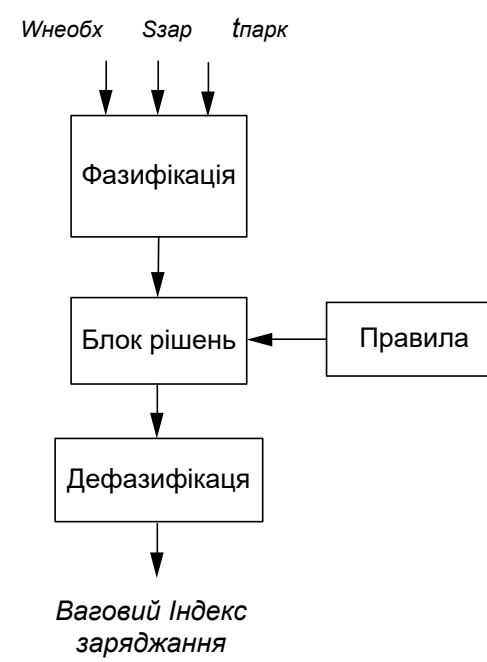
Модель LSTM виявилась найкращою моделлю для прогнозування генерації сонячної енергії у мікрмережах, оскільки забезпечує високу точність прогнозу, враховує довготривалі залежності та здатна адаптуватися до мінливих погодних умов.



Алгоритм керування зарядними станціями при умові обмеження споживання та наявності прогнозування сонячної генерації

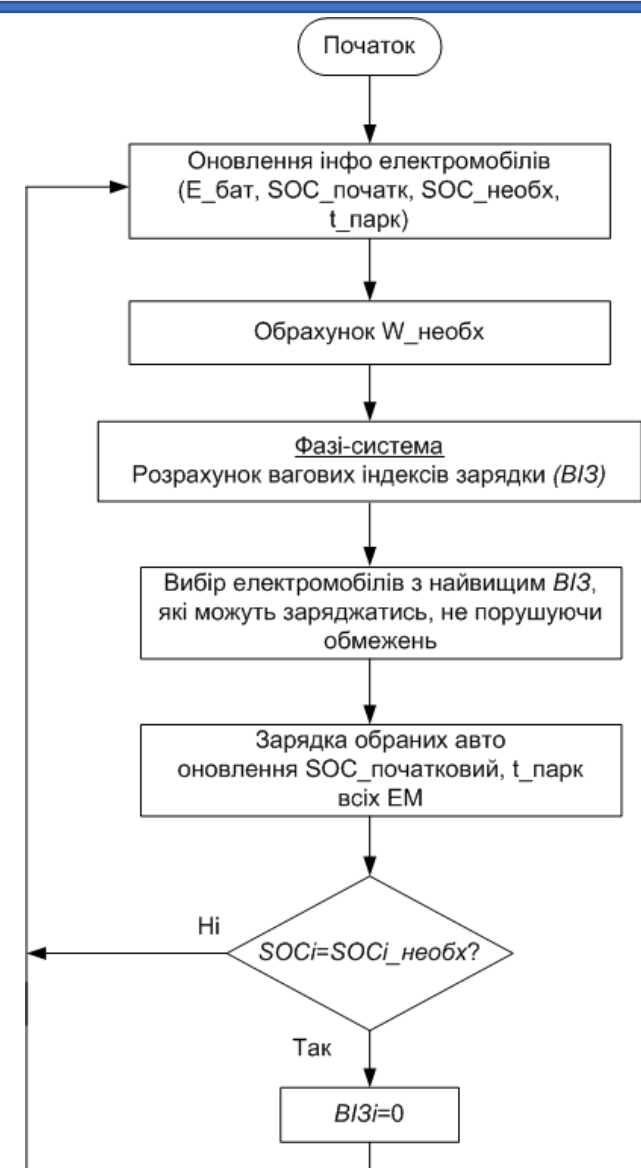
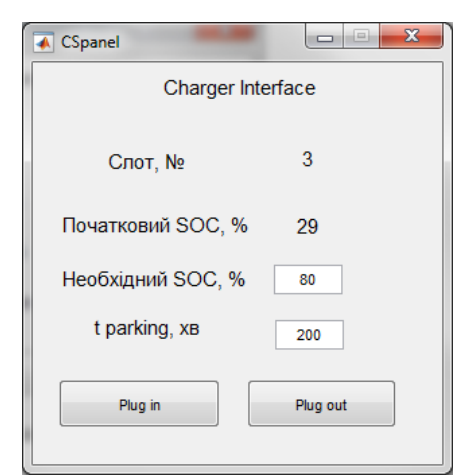


Структура системи керування зарядною станцією



Застосування нечіткої логіки

Графічний інтерфейс користувача зарядною станцією



Запропонований алгоритм контролю заряджання



Характеристики функцій належності


	Змінна	Форма	Терми та їх діапазони/значення
Вхід	Необхідна к-сть енергії $W_{\text{необх}}$ кВт·год	Трапеція	Дуже мала [0, 3.5] Мала [5, 7.5] Середня [10, 13] Велика [16, 22]
	Потужність $S_{\text{зар}}$ кВт	Трапеція	Низька [2.9, 3.6] Висока [6.5, 7.2]
	Час парковки $t_{\text{парк}}$ хв.	Трапеція	Дуже короткий [0, 75] Короткий [122, 180] Середній [240, 300] Довгий [360, 420] Дуже довгий [460, 540]
Вихід	Ваговий індекс заряджання ВІЗ	Трикутник	Дуже низький [0.05] Низький [0.25] Середній [0.45] Високий [0.7] Дуже високий [1]

$$tr(x; a; b; c; d) = \begin{cases} 0, & \text{для } x \leq a \\ \frac{x-a}{b-a}, & \text{для } a \leq x \leq b \\ 1, & \text{для } b \leq x \leq c \\ \frac{c-x}{c-b}, & \text{для } c \leq x \leq d \\ 0, & \text{для } d \leq x \end{cases}$$


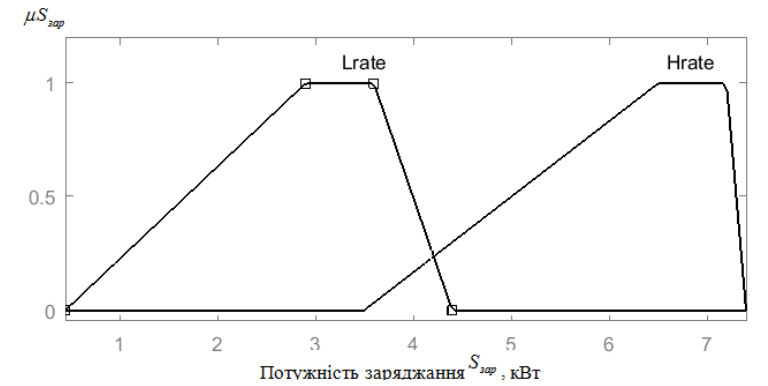
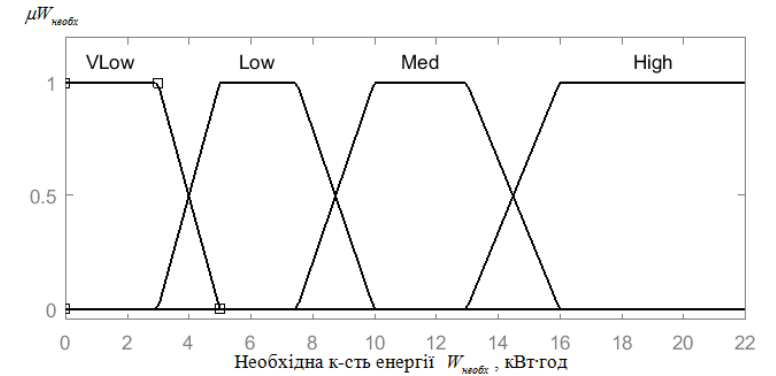
Трапецевидна функція належності

$$t(x; a; b; c) = \begin{cases} 0, & \text{для } x \leq a \\ \frac{x-a}{b-a}, & \text{для } a \leq x \leq b \\ \frac{c-x}{c-b}, & \text{для } b \leq x \leq c \\ 0, & \text{для } x \geq c \end{cases}$$

Трикутна функція належності



Тривимірне відображення вхідних та вихідних функцій належності

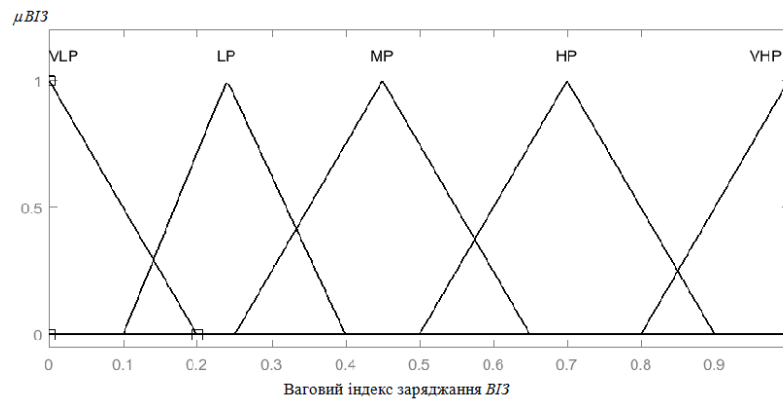




Правила нечіткого керування

$S_{mp} = \text{Висока}$		Тривалість парковки t_{park}				
		Дуже коротка	Коротка	Середня	Довга	Дуже довга
Необхідна для зарядки енергія $W_{\text{необ}} \text{ кВт-год}$	Дуже мала	СП _{0,9}	СП _{0,6}	НП _{0,7}	ДНП _{0,6}	ДНП _{0,4}
	Мала	ВП _{0,5}	СП ₁	СП _{0,7}	НП _{0,7}	ДНП _{0,5}
	Середня	ДВП _{0,4}	ВП ₁	ВП _{0,7}	СП _{0,6}	НП _{0,5}
	Висока	ДВП _{0,9}	ДВП _{0,7}	ВП _{0,9}	СП ₁	СП _{0,6}

$S_{mp} = \text{Низька}$		Тривалість парковки t_{park}				
		Дуже коротка	Коротка	Середня	Довга	Дуже довга
Необхідна для зарядки енергія $W_{\text{необ}} \text{ кВт-год}$	Дуже мала	СП _{0,9}	СП _{0,7}	НП _{0,4}	ДНП _{0,5}	ДНП _{0,3}
	Мала	ВП _{0,6}	СП _{0,9}	СП _{0,5}	НП _{0,6}	ДНП _{0,5}
	Середня	ДВП _{0,5}	ВП _{0,8}	ВП _{0,6}	СП _{0,5}	НП _{0,7}
	Висока	ДВП ₁	ДВП _{0,8}	ВП _{0,8}	СП _{0,9}	СП _{0,7}



Функція належності для вихідного VIZ



Графічний вигляд спроектованих фазі-правил



Отримання Вагового індексу зарядки (ВІЗ)

$$\mu\text{ВІЗ}(EMi) = \mu W_{\text{необх}} \cap \mu S_{\text{зар}} \cap \mu t_{\text{парк}}(EMi) = \min[\mu W_{\text{необх}}, \mu S_{\text{зар}}, \mu t_{\text{парк}}]_{EMi}$$

де \cap - оператор AND; $\mu\text{ВІЗ}$, $\mu W_{\text{необх}}$, $\mu S_{\text{зар}}$, $\mu t_{\text{парк}}$ - функції належності, що відносяться до вагового індекса заряджання ВІЗ, необхідної енергії для зарядки, потужності заряджання та часу парковки електромобіля

Цільова функція з рішенням про дозвіл на заряджання

$$\max F(t) = \sum_{\text{Слот}(i)} \text{ВІЗ}_{(\text{Слот}(i),t)} \times \text{Ріш}_{(\text{Слот}(i),t)}$$

Обмеження максимальної на мінімальної напруги на шині

$$V_{\min} \leq V(it) \leq V_{\max}$$

Обмеження попереднього рішення

$$\text{Ріш}_{(\text{Слот}(i),t)} = 0, \quad \text{якщо} \quad \text{SOC}_{(\text{Слот}(i),t)} \geq \text{SOC}_{\text{необх}(\text{Слот}(i),t)}$$

$$\text{Ріш}_{(\text{Слот}(i),t)} = 0, \quad \text{якщо} \quad \text{Статус}_{(\text{Слот}(i),t)} = 0$$

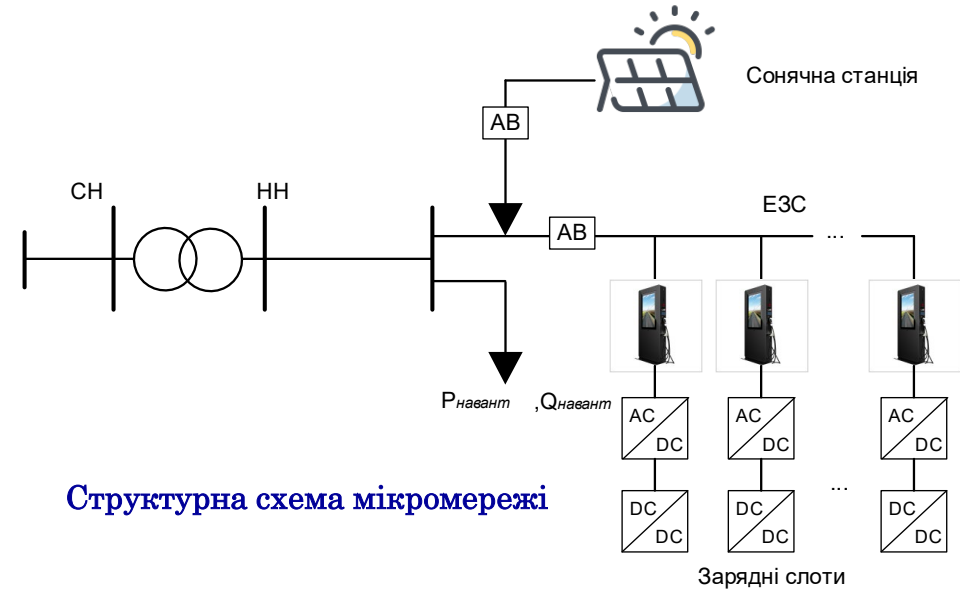
Обмеження потужності

$$S_{EM(t)} + S_{\text{навант}} \leq S_t^{\max} + S_t^{PV},$$

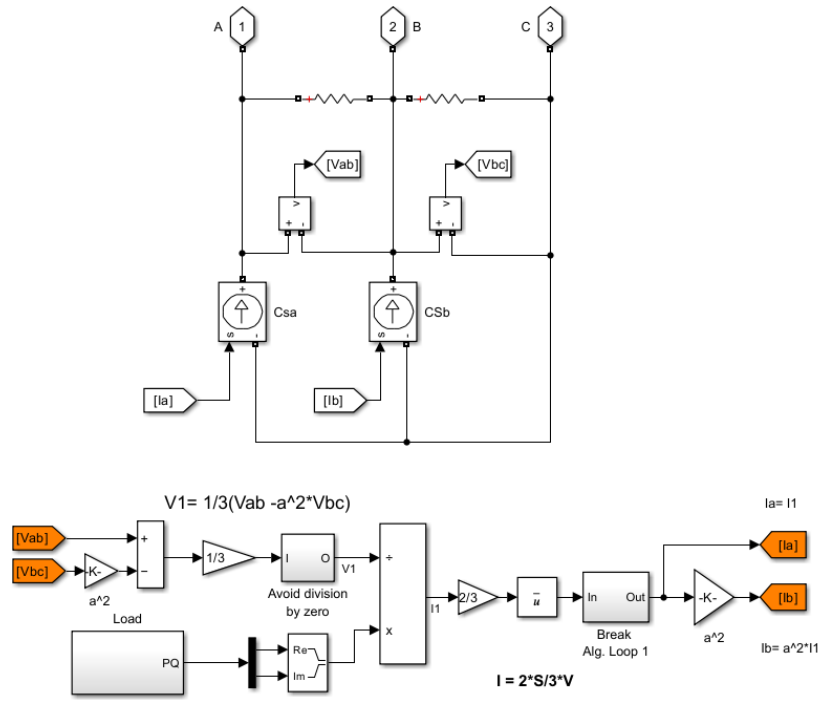
$$S_{EM(t)} = \sum_{\text{Слот}(i)} \frac{P_{\text{зар}(\text{Слот}(i),t)} \times \text{Ріш}_{(\text{Слот}(i),t)}}{\eta_{(\text{Слот}(i))}}$$

Обмеження за ціною на електроенергію

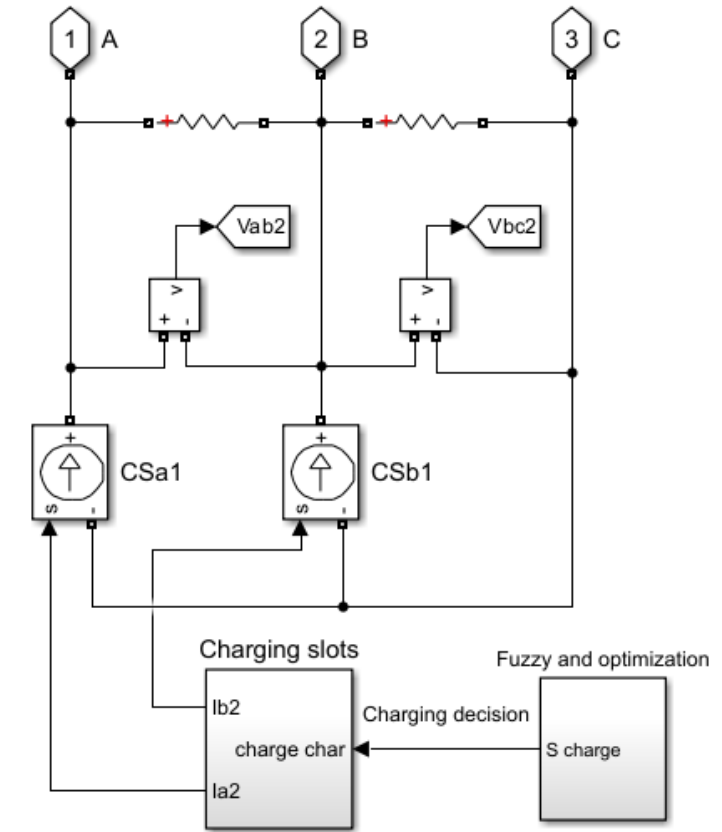
$$P_{\text{зар}} = k_c \cdot P_{\text{зарmax}}$$



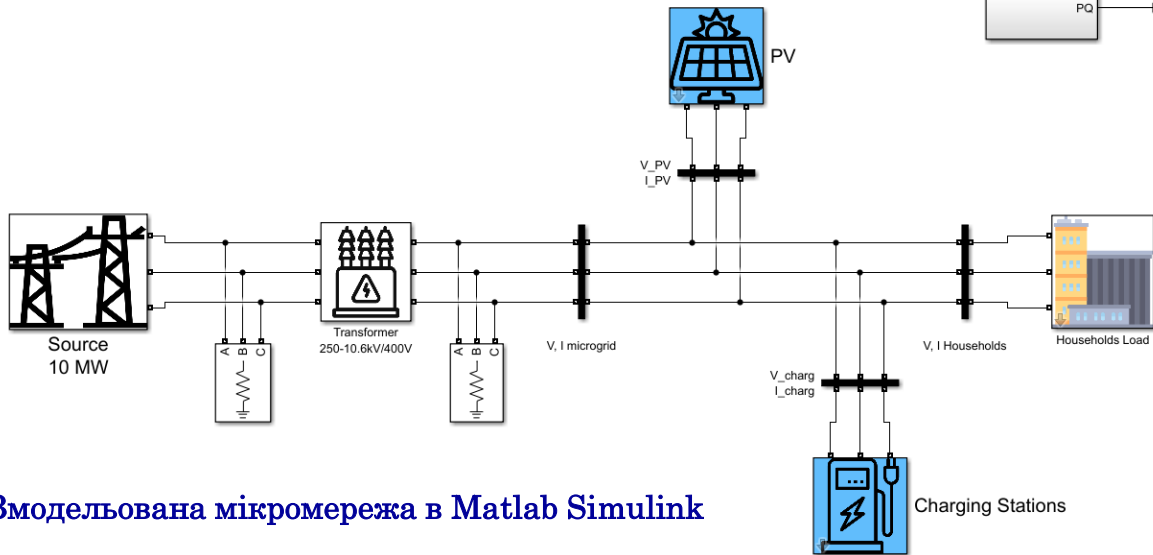
Структурна схема мікромережі



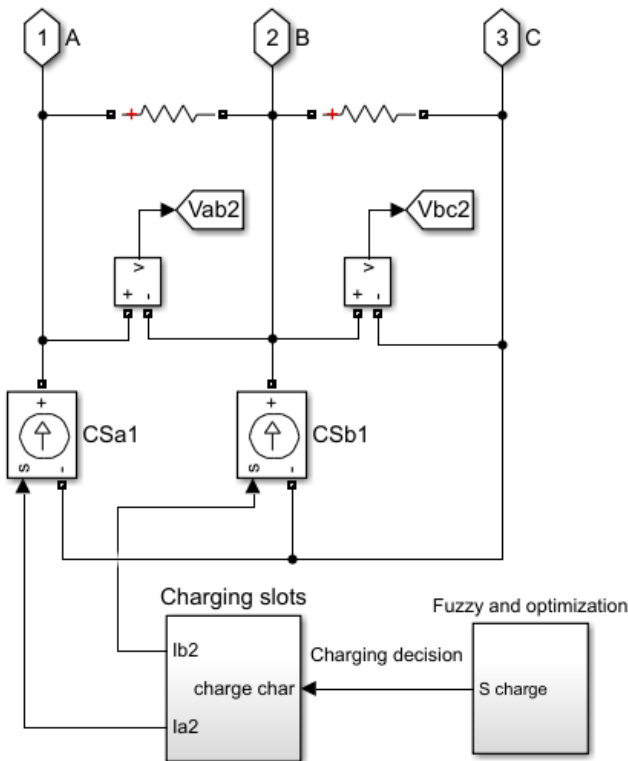
Модель підключення навантаження домогосподарств та розрахунок напруг і струму навантаження



Модель зарядної станції



Змодельована мікромережа в Matlab Simulink



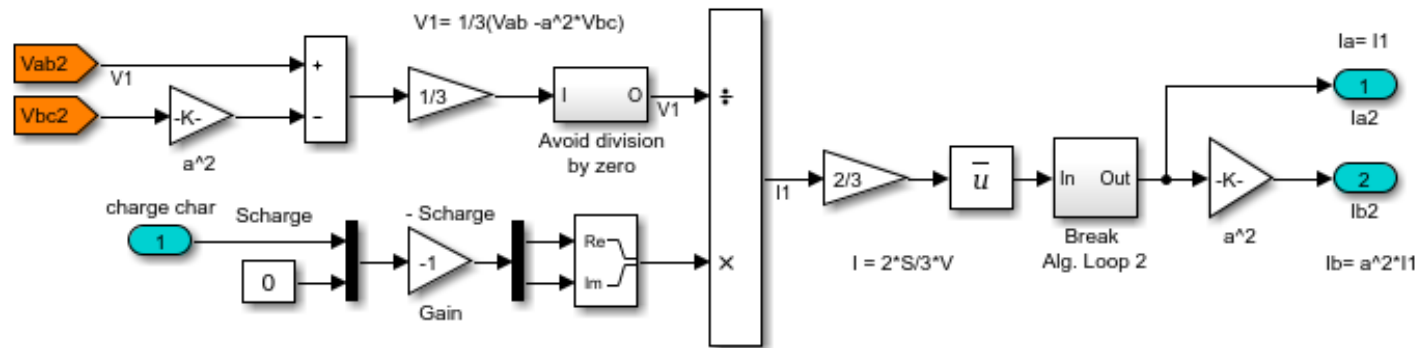
Точка приєднання зарядної станції до мережі

В цій моделі обчислення фазної напруги визначається через міжфазні напруги V_{abPV} та V_{bcPV} за формулою:

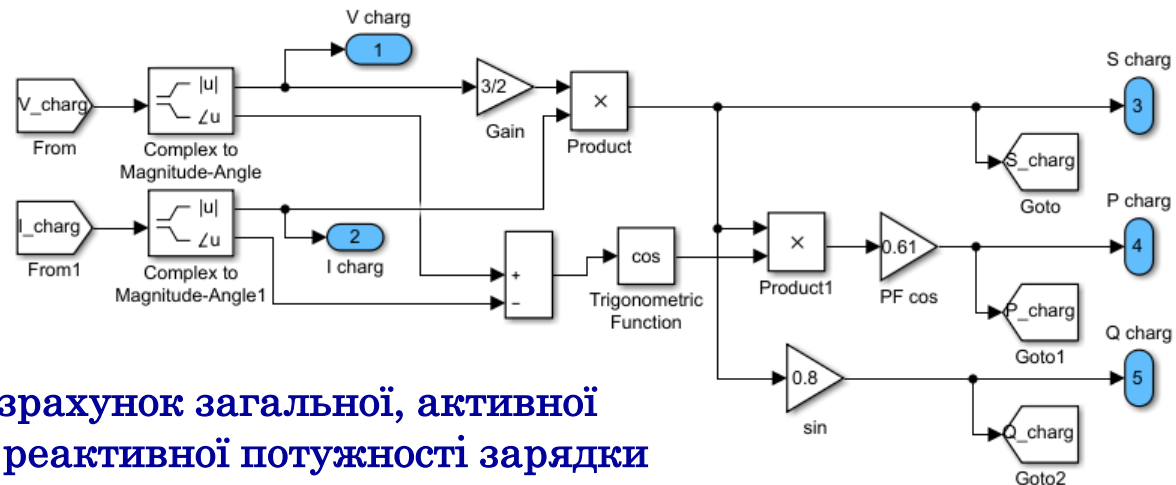
$$V_1 = \frac{1}{3} (V_{abPV} - a^2 \cdot V_{bcPV})$$

Розрахунок струму використовуючи отриману напругу V_1 обчислюється як:

$$I = \frac{2S}{3V_1}$$



Обчислення напруги та струму зарядної станції




Розрахунок загальної, активної та реактивної потужності зарядки

Активна потужність (P) визначається за формулою:


$$P = U \cdot I \cdot \cos\varphi$$

Фазний струм $I_a = I_1$, а фазний струм I_b визначається через перетворення:


$$I_b = a^2 \cdot I_1$$




Попит на електроенергію протягом 24 годин на основі запропонованого методу зарядки. (Коричнева - загальний попит з електромобілями, синя - тільки навантаження домогосподарств)



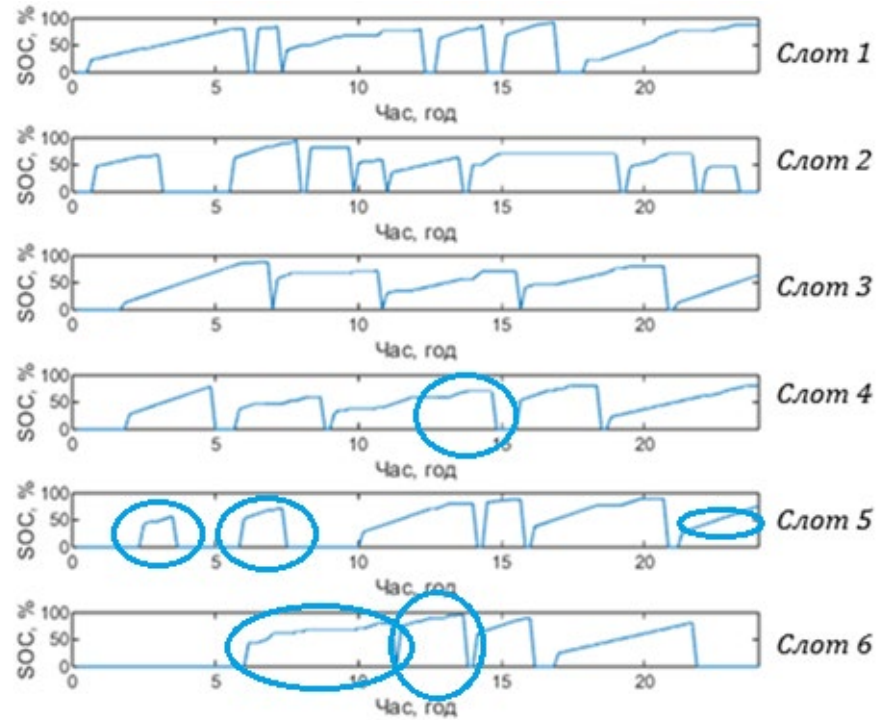
Попит на електроенергію протягом 24 годин на основі запропонованого методу зарядки з врахуванням прогнозування генерації сонячної станції




Навантаження зарядної станції для запропонованого методу зарядки



Навантаження зарядної станції для запропонованого методу зарядки з врахуванням прогнозування генерації сонячної станції



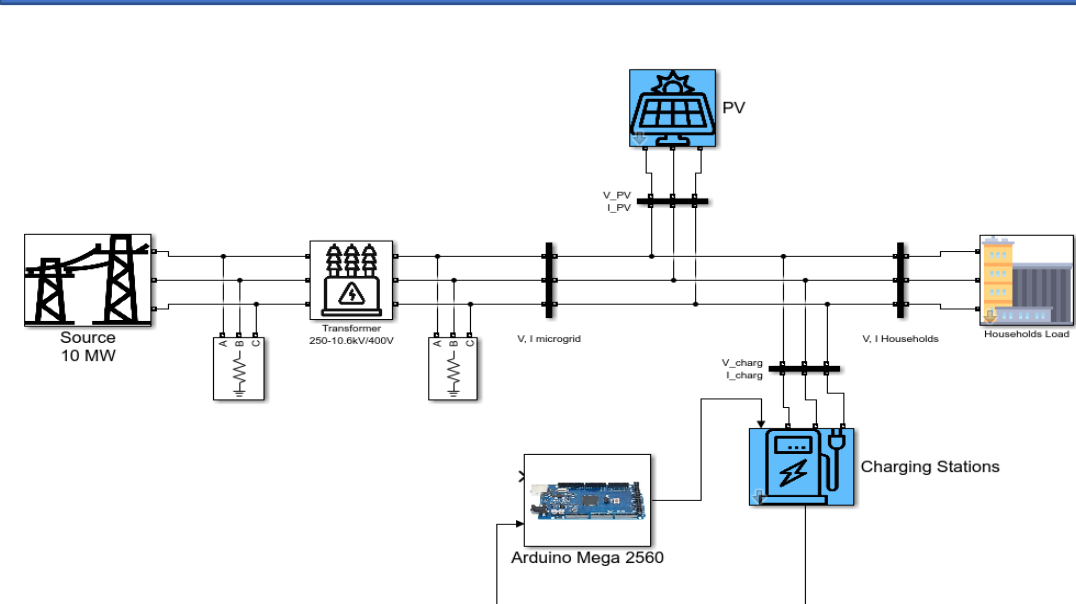
Зміни рівня заряду *SOC* електромобілів на 6 зарядних слотах під час заряджання запропонованим алгоритмом (ВІЗ). (пряма під кутом - електромобіль заряджається, горизонтальна пряма - ЕМ утримується)




Зміни рівня заряду *SOC* електромобілів на 6 зарядних слотах під час заряджання звичайним контрольованим алгоритмом (пряма під кутом - електромобіль заряджається, горизонтальна пряма - ЕМ утримується)

Спожита енергія в мережі для різних методів зарядки


	Без EV	Запропонований без врахування прогнозу	ВІЗ з урахуванням прогнозування
Загальна спожита енергія за 24 год $W_{\text{заг}}$, кВт·год	1825,2	2292,1	2412,3
Спожита енергія EV за 24 год $W_{\text{ЕМ}}$, кВт·год	1825,2	467,5	587,1



Загальний вид всієї моделі в Matlab Simulink з підключенням мікроконтролера



Зарядний слот та місце підключення контролера



Зовнішній вигляд використаної плати Arduino Mega 2560

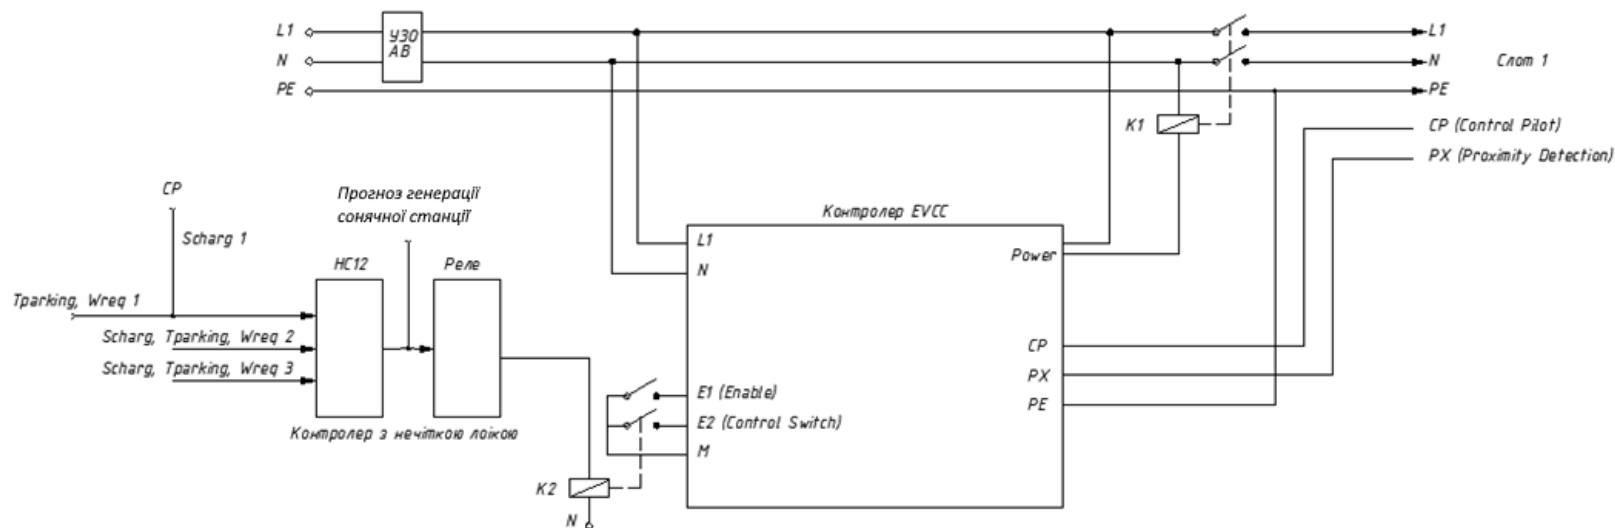
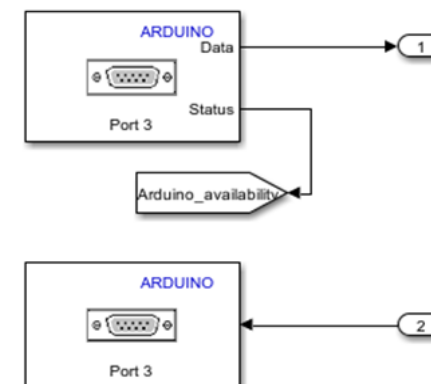


Схема підключення контролера з запропонованою системою



Використані в моделі блоки бібліотеки Arduino

У ході виконання науково-дослідної роботи розроблено комплексний підхід до прогнозування сонячної генерації та керування зарядними станціями електротранспорту в мікромережах із використанням методів математичного моделювання, машинного навчання та інтелектуальних алгоритмів. Результати роботи підтверджують ефективність запропонованих моделей та алгоритмів для підвищення стабільності та ефективності роботи зарядної інфраструктури в умовах інтеграції відновлюваних джерел енергії.

Основні досягнення дослідження:

1. Розробка та оцінка моделей прогнозування сонячної генерації:

- Використання LSTM-мережі забезпечило високу точність прогнозування активної потужності сонячних електростанцій ($RMSE = 452,56$ кВт, $MAE = 354,97$ кВт, $R^2 = 0,9676$), що дозволяє враховувати довготривалі залежності та змінність метеорологічних параметрів.
- Модель SARIMA (1,0,1)x(2,1,0,24) продемонструвала ефективність ($RMSE = 258,57$ кВт, $MAE = 1259$ кВт, $R^2 = 0,92$) для середньострокового прогнозування, зокрема для аналізу сезонних коливань, що є критичним для балансування мікромереж.
- Модель випадкового лісу ($RMSE = 1362,17$ кВт, $MAE = 735,5$ кВт, $R^2 = 0,61$) показала високу адаптивність до короткострокових прогнозів, враховуючи нелінійні взаємозв'язки між параметрами.

2. Порівняння запропонованого та звичайного алгоритму заряджання:

- Використання методу пріоритетного розподілу енергії забезпечує гнучке управління навантаженням, що дозволяє зменшити енергоспоживання у години пікового навантаження на 20% у порівнянні із звичайним контрольованим заряджанням.
- Запропонований алгоритм зменшує середньоквадратичне відхилення між необхідною та доставленою енергією для всіх електромобілів із 3,245 кВт до 2,799 кВт, що свідчить про більш точне відповідність запиту на заряджання реальним можливостям мережі.
- Для критичних електромобілів (тих, яким необхідний максимальний заряд) різниця між запитаною і отриманою енергією зменшилася з 4,548 до 3,869, що свідчить про покращену ефективність алгоритму.

3. Оптимізація навантаження та зменшення перевантажень:

- Запропонований алгоритм дозволяє уникнути перевищення допустимого навантаження мережі (120 кВт) та підтримувати її стабільність, навіть у періоди пікового попиту.
- Максимальне завантаження лінії в мережі для різних сценаріїв показало:
 - 99% без електромобілів;
 - 98% для запропонованого методу без прогнозу;
 - 97% для запропонованого методу із прогнозуванням сонячної генерації.
- У випадку неконтрольованого заряджання мережа зазнавала перевантаження до 16%, що може призвести до аварійних ситуацій.

4. Підвищення ефективності розподілу енергії:

- У порівнянні зі звичайним методом, запропонований алгоритм гарантує заряджання всіх електромобілів, включаючи ті, які підключені до останніх слотів (5-го та 6-го), тоді як у звичайному алгоритмі 4 електромобілі залишалися без заряду через перевищення ліміту потужності.
- Ефективність запропонованого підходу підкріплюється симуляцією 34 електромобілів у середовищі MATLAB&Simulink, що підтвердило оптимальне використання наявних ресурсів.

5. Енергоспоживання та баланс у мережі:

- Загальне енергоспоживання у мережі за 24 години склало:
 - 1825,2 кВт год без електромобілів;
 - 2292,1 кВт год для запропонованого алгоритму без прогнозування;
 - 2412,3 кВт год для алгоритму із врахуванням прогнозу.
- Споживана електромобілями енергія склала:
 - 467,5 кВт год для запропонованого методу;
 - 587,1 кВт год для алгоритму із прогнозуванням.
- Збільшене загальне енергоспоживання пояснюється тим, що пріоритет заряджання отримували електромобілі із більш високими потребами, що дозволяло більш ефективно використовувати ресурси зарядної станції.

Таким чином, проведене дослідження доводить, що розроблені моделі і засоби дозволяють підвищити енергоефективність зарядної інфраструктури, зменшити навантаження на електромережі та створити гнучку систему керування зарядними станціями в умовах використання сонячної генерації.