

ПОРІВНЯННЯ ПІДХОДІВ ДО ПРОГНОЗУВАННЯ НЕТТО-НАВАНТАЖЕННЯ ВІРТУАЛЬНИХ ОБ'ЄДНАНЬ ЕНЕРГЕТИЧНИХ ОБ'ЄКТІВ

В.О. Мірошник*, **В.В. Сичова****

Інститут електродинаміки НАН України,
пр. Берестейський, 56, Київ, 03057, Україна
e-mail: miroshnyk.volodymyr@gmail.com, shorl@ukr.net

У роботі здійснено порівняльний аналіз трьох підходів до короткострокового прогнозування нетто-навантаження віртуальних об'єднань енергетичних об'єктів, сформованих із будівель різного призначення та масивів сонячної генерації. Дослідження спрямоване на аналіз впливу рівня агрегації вхідних часових рядів на точність прогнозів сумарного споживання, генерації СЕС та сальдованої потужності. Усі експерименти виконано на єдиній вибірці даних UCSD Microgrid із застосуванням однотипної моделі Transformer, що дало змогу виокремити ефект від впливу структури даних, а не архітектури моделі. Результати показали, що для навантаження найвищу точність забезпечує дезагрегований підхід, тоді як для сумарного нетто-навантаження оптимальною є часткова агрегація, яка дає змогу окремо моделювати портфель споживання і генерації. Для PV-генерації всі три стратегії демонструють підвищену чутливість до асиметрії розподілу та нульових значень, причому агреговані прогнози забезпечують нижчий рівень похибки порівняно з bottom-up моделями. Отримані результати дають можливість обґрунтувати вибір рівня агрегації та підходів до прогнозування для задач віртуальних електростанцій і локальних енергетичних ринків. Бібл. 14, рис. 4.

Ключові слова: короткострокове прогнозування навантаження, агрегатори, локальні ринки електроенергії, нейронні мережі, віртуальні електростанції.

Сучасна трансформація оптового ринку електричної енергії України, що передбачає активізацію участі балансуючих груп, агрегаторів та формування локальних енергетичних ринків, суттєво посилює вимоги до точності короткострокових погодинних прогнозів на горизонті від однієї до семи діб. Прогнозні моделі формують основу участі у ринку “на добу наперед” та внутрішньодобовому ринку, визначають очікувані небаланси й економічні результати учасників, а також впливають на оптимізацію режимів віртуальних електростанцій. В умовах швидкого зростання частки відновлюваних джерел, установок зберігання енергії (УЗЕ), розподіленої генерації та керованого попиту особливої актуальності набуває вибір адекватної моделі агрегування даних для прогнозування сумарної потужності віртуального об'єднання учасників ринку, оскільки рівень агрегації визначає статистичні властивості ряду, надійність прогнозу та складність моделювання.

Питання цифрової трансформації енергетичних систем, що формує підґрунтя для впровадження прогнозних моделей у віртуальних об'єднаннях, детально розглянуто в роботі [1], де обґрунтовано роль автоматизації та інтелектуальних алгоритмів у забезпеченні гнучкості та стійкості енергетичних процесів.

Особлива залежність роботи мікромереж від точності прогнозування підкреслена в [2, 3], де аналіз ізольованого режиму показує критичну роль моделей короткострокового прогнозування для визначення оптимальних стратегій управління розосередженими енергетичними ресурсами (DER).

Для локальних систем, описаних, зокрема, в роботі [4], де агрегатор оптимізує графіки навантаження локальної мікромережі із дизель-генераторами та програмами керування попитом, необхідність якісних прогнозів графіків споживання прямо пов'язана із мінімізацією паливних витрат та витрат на електроенергію для покриття попиту. Для операторів розподільчих мереж та системного оператора точність прогнозів сумарних навантажень і втрат безпосередньо впливає на вартість небалансів і закупівель енергії для компенсації технічних втрат, як показано у [5]. У цьому контексті для віртуальних об'єднань учасників ринку необхідним є обґрунтований вибір структури прогнозної моделі за рівнем агрегації даних.

У сучасній науковій літературі та практиці прогнозування розглядають три підходи:

- 1) пряме прогнозування агрегованого (сальдованого, нетто-навантаження) часового ряду, яке є різницею між сумарним споживанням та сумарною генерацією в об'єднанні;
- 2) часткова агрегація з окремим прогнозуванням сумарного споживання та сумарної генерації (інколи — за технологіями ВДЕ);
- 3) дезагреговане прогнозування кожного споживача або генератора з подальшою агрегацією, при якому будується окрема модель для кожного об'єкта, або площадки (bottom-up підхід).

Мета дослідження полягає у порівнянні трьох підходів до короткострокового прогнозування нетто-навантаження віртуального об'єднання енергетичних об'єктів різного типу та визначенні впливу рівня агрегації часових рядів на точність прогнозу сумарного споживання, PV-генерації та сальдованої потужності.

Пряме прогнозування агрегованого ряду історично є базовим для задач короткострокового прогнозування сумарних навантажень енергосистем. У [6] розроблено методику моделювання та прогнозування технологічної складової сумарного електричного навантаження обласної енергосистеми із переважанням промислового споживання. Автори розділяють сумарне навантаження на комунально-побутову та технологічну складові й показують, що для технологічної складової агреговане прогнозування сумарного навантаження енергоємних підприємств за допомогою інтегрованих авторегресійних моделей Бокса–Дженкінса (ARIMA) забезпечує стабільніші результати порівняно із прогнозуванням окремих підприємств та з багат шаровими перцептронами: середня відносна похибка MAPE для сумарного ряду за добового горизонту прогнозування становить близько 3,8 %, тоді як для окремих підприємств похибка зростає більше за 6 %.

Це узгоджується із загальними висновками робіт, присвячених впливу рівня агрегації на точність прогнозування. У [7] показано, що для груп домогосподарств зростання розміру групи понад 20–50 споживачів призводить до суттєвого зменшення MAPE для агрегованого навантаження. Дослідження, проведені в [9, 10], на матеріалі різних енергосистем продемонстрували різке зростання передбачуваності (зменшення дисперсії похибок) із підвищенням рівня агрегації.

Статистичні моделі типу SARIMA, ARIMAX, методи експоненційного згладжування, а також прості моделі машинного навчання (градієнтний бустинг, випадкові ліси) добре працюють на агрегованому рівні, де ряд має виражену добову й тижневу періодичність, відносно невелику варіативність та стабільні автокореляційні властивості [6]. Для агрегованих рядів також найпростіше отримувати оцінки невизначеності – класичні прогнозні інтервали ARIMA, байєсівські часові моделі, квантільна регресія дають добре інтерпретовані довірчі інтервали для сумарного навантаження, що особливо важливо у випадку оцінювання ризику небалансів для великих портфелів.

Недоліком повної агрегації є втрата детальної інформації про структуру портфеля. Як показано в [8], нетто-навантаження, що є різницею між сумарним попитом і сумарною генерацією ВДЕ, має складний характер залежності від метеорологічних та поведінкових факторів; у разі прямого прогнозування такого ряду моделі не можуть повною мірою використати окремі предиктори для попиту та генерації, що призводить до гіршої точності порівняно з підходами, де ці компоненти прогнозуються роздільно. Підкреслюється, що виділення технологічної складової як окремого прогнозного об'єкта дає змогу краще врахувати особливості промислового навантаження. У випадку віртуальної електростанції або локального ринку це означає, що пряме прогнозування лише сальдованої потужності не дає змогу оптимізувати внутрішні режими DER, УЗЕ і програм керування попитом.

Часткова агрегація – коли окремо прогнозуються сумарне споживання і сумарна генерація (або окремі технологічні групи генерації) – у низці робіт показана як компроміс, що дає кращу точність, ніж пряме прогнозування сальдованого ряду, та водночас уникає вибухового росту складності, характерного для повністю bottom-up підходу. У [8] порівнюються три стратегії прогнозування нетто-навантаження: пряме прогнозування агрегованого нетто-навантаження, часткова агрегація (окремо портфель попиту та портфель ВДЕ) та повністю дезагреговане прогнозування об'єктів з подальшою агрегацією. За результатами багатьох

сценаріїв саме частково агрегований підхід забезпечив найменшу сумарну похибку (за RMSE і CRPS), перевищивши за точністю як чисто агрегований, так і повністю дезагрегований підходи. Це узгоджується з висновками [7] та ін. про те, що для середніх рівнів агрегації добре налаштовані моделі машинного навчання (градієнтний бустинг, випадкові ліси, підтримувальні вектори) дають найбільший вигравш у точності.

Окрему важливу ілюстрацію часткової агрегації для задач, близьких до задачі віртуального об'єднання, надає робота [5], присвячена «розумному» управлінню втратами електроенергії в розподільчих мережах за допомогою глибинних нейронних мереж. Автори розглянули два концептуальні підходи: 1) пряме прогнозування агрегованого часового ряду сумарних втрат у мережі; 2) окреме прогнозування навантажень у вузлах схеми за допомогою мереж на основі LSTM із подальшим обчисленням втрат на основі розрахунків режиму мережі. Для обох підходів було застосовано глибинні архітектури (LSTM, eResNet) із розширеною попередньою обробкою даних (виявлення й заміна аномалій через DBSCAN), проте саме другий підхід, який за структурою відповідає частковій агрегації (окремі компоненти – вузлові навантаження, потім агреговані втрати), забезпечив істотно меншу похибку: MAPE для втрат, розрахованих на основі прогнозованих вузлових навантажень на очищених даних, становила близько 3,29 %, тоді як для прямого прогнозування сумарних втрат – понад 20 %. Важливо, що така побудова дає змогу у природний спосіб урахувувати зміну топології мережі на етапі розрахунку режиму без перенавчання моделей прогнозування навантажень, що є безпосередньою аналогією до задач віртуальних електростанцій (VPP), де змінюється конфігурація портфеля DER.

Отже, часткова агрегація є природною для сценаріїв, коли для віртуальної електростанції або локального ринку важливо окремо моделювати поведінку портфеля споживання (залежного від календаря, цін, поведінкових факторів) і портфеля генерації (залежної від метеоумов, технічних характеристик установок), а також втрат і технічних обмежень мережі. На цьому рівні агрегації особливо ефективними є глибинні нейронні мережі (LSTM, GRU, CNN–LSTM, eResNet) та ансамблеві методи (градієнтний бустинг, багатомодельні ансамблі з динамічним зважуванням), які здатні відтворювати складні нелінійні залежності та багатомасштабну сезонність [5, 7, 8].

Повністю дезагрегований підхід (bottom-up), за яким прогнозуються окремі споживачі, електростанції або вузли, дає змогу максимально використати гетерогенність портфеля. Саме такий підхід частково реалізовано в роботі [3], де окремі енергоємні підприємства розглядаються як об'єкти із власними часовими рядами навантаження, для яких будуються окремі моделі, а потім виконується агрегація для отримання технологічної складової сумарного навантаження. Порівняльний аналіз показав, що, попри можливість більш детального врахування індивідуальних режимів, похибка прогнозу за схемою «окремі підприємства + агрегація» виявилася більшою ніж при безпосередньому прогнозуванні суми навантажень, тоді як ARIMA-моделі для агрегованого ряду продемонстрували кращу стабільність та відсутність систематичної складової похибки [6]. Подібні висновки щодо обмеженості bottom-up підходу за великої кількості об'єктів були отримані в роботі [11], де показано, що за реалістичних обмежень на кластеризацію smart-метерних даних bottom-up-прогнозування може давати гіршу точність, ніж один «single-model» прогноз для агрегованого часового ряду. Використання кластеризації та ієрархічних схем дає змогу частково зменшити похибки, однак значно ускладнює архітектуру системи прогнозування [12].

Для віртуальних об'єднань bottom-up підхід є природним там, де кількість учасників відносно невелика (локальні ринки, мікромережі, корпоративні портфелі) і де важлива поведінка кожного DER, наприклад, для оптимізації режимів окремих УЗЕ, генераторів чи реалізації таргетованих програм керування попитом. Тут виправдане застосування складних об'єктно-орієнтованих моделей – від ARIMA/Prophet і класичних алгоритмів машинного навчання до індивідуальних LSTM/GRU-мереж для окремих споживачів чи вузлів [5–6, 11–12]. Однак оцінювання невизначеності в такій схемі є найскладнішим, оскільки потребує моделювання спільного розподілу похибок великої кількості часових рядів; просте припущення незалежності суттєво недооцінює ризик сумарного небалансу портфеля.

Оцінювання невизначеності прогнозів є принципово важливим, оскільки саме від характеристик розподілу похибок (а не лише від середньої MAPE) залежать оптимальні стратегії участі VPP у РДН/ВДР та балансуючому ринку. Для агрегованого підходу побудова імовірнісних прогнозів технічно найпростіша: низка робіт демонструє успішне застосування Bayesian ARIMA, квантильного градієнтного бустингу та bootstrap-ансамблів для отримання довірчих інтервалів та квантильних прогнозів для сумарного навантаження [7–10]. Частково агрегований підхід потребує спільного моделювання невизначеності окремих компонентів (споживання, генерація, втрати), проте розмірність задачі все ще прийнятна, і застосування багатовимірних квантильних моделей та *formula*-підходів є практично реалізованим [5,7–8]. У bottom-up підході повноцінна оцінка невизначеності потребує ієрархічних байєсівських моделей або великих ансамблів сценаріїв; на практиці це часто замінюється спрощеними схемами, що знижують достовірність оцінки невизначеності прогнозу.

Отже, з погляду поєднання точності прогнозу, складності реалізації та можливостей оцінювання невизначеності найбільш збалансованим для віртуальних об'єднань виглядає підхід часткової агрегації, що підтверджується як зарубіжними дослідженнями, так і українськими роботами, орієнтованими на прогнозування технологічної складової навантаження та втрат.

У подальшому дослідженні, присвяченому вдосконаленню моделей прогнозування генерації та споживання електроенергії віртуальних об'єднань учасників ринку, доцільно реалізувати і порівняти всі три підходи на єдиній вибірці даних VPP/агрегатора: пряме прогнозування нетто-часового ряду, часткова агрегація (сумарне споживання та сумарна генерація, можливо з поділом за технологіями) та дезагреговане прогнозування для кластерів споживачів і електростанцій. Оцінювання має включати як класичні метрики (MAPE, RMSE), так і імовірнісні показники (CRPS, каліброваність квантилів), а також економічні індикатори – очікувану вартість небалансів і чутливість фінансового результату до зростання похибки прогнозу. Це дасть змогу сформулювати практичні рекомендації щодо вибору рівня агрегації та класу моделей для різних сценаріїв застосування VPP на оптовому та локальних ринках.

Дані для прогнозування. Для дослідження використано відкритий багаторічний набір даних UCSD Microgrid, представлений у роботі [13]. Цей набір містить високочастотні (15-хвилинні) дані реального електроспоживання будівель різних типів кампусу та активної потужності фотогальванічних установок, що робить його репрезентативним для задач моделювання енергетичних потоків у віртуальних об'єднаннях та мікромережах із гетерогенними навантаженнями та розосередженою генерацією.

Структура даних охоплює паралельні часові ряди навантажень будівель від адміністративних та навчальних корпусів до центрів обслуговування і PV-генерації окремих масивів панелей, у такому випадку часові позначки синхронізовані. Для кожного об'єкта доступні декілька років історичних записів.

На основі 15-хвилинних часових рядів було сформовано погодинні дані споживання та генерації СЕС для набору об'єктів, що формують умовне віртуальне об'єднання учасників ринку. Були виключені об'єкти зі значною кількістю пропущених даних. Також для безпосереднього прогнозування було обрано часовий період з 13.08.2018 до 29.02.2020 включно. У ньому відсутні пропуски даних за обраними об'єктами.

У табл. 1 наведено статистичні характеристики наявних часових рядів (* без урахування нульових значень). Часовий ряд нетто-навантаження має середнє значення близько –1311 кВт і високу варіативність, оскільки поєднує стабільне споживання та різку змінність генерації. Періодичне переходження в додатну область указує на години профіциту, коли виробіток перевищує попит. Сумарне споживання характеризується суттєво більшою передбачуваністю: середні значення розташовані в межах –1500...–900 кВт, а стандартне відхилення є відносно малим. Такий характер є типовим для великої групи будівель із регулярною добовою та тижневою сезонністю.

Таблиця 1

	MEAN	STD	MIN	MAX	MEAN*	STD*	MIN*
Total	-1311,1	342,6	-2226,6	105,4	-1311,1	342,6	-2226,6
Total Consumption	-1540,3	305,9	-2225,6	-925,2	-1540,3	305,9	-2225,6
Total PV	229,2	342,3	-3,5	1215,7	229,2	342,3	-3,5
CenterHall	-110,5	44,1	-214,4	-42,9	-110,5	44,1	-214,4
EastCampus	-109,6	18,8	-182,7	-44,8	-109,6	18,8	-182,7
GalbraithHall	-189,5	54,3	-339,2	-79,3	-189,5	54,3	-339,2
GeiselLibrary	-518,4	110,3	-746,5	-278,4	-518,4	110,3	-746,5
Gilman	-71,9	27,8	-172,9	-21,0	-71,9	27,8	-172,9
Hopkins	-54,2	10,8	-104,1	-35,6	-54,2	10,8	-104,1
Mandeville	-30,0	10,4	-67,2	-12,7	-30,0	10,4	-67,2
MusicBuilding	-91,2	17,3	-149,9	-44,5	-91,2	17,3	-149,9
PoliceDepartment	-37,2	7,4	-65,7	-9,7	-37,2	7,4	-65,7
RadyHall	-57,2	18,3	-116,0	-16,6	-57,2	18,3	-116,0
SocialScience	-142,9	22,4	-220,2	-90,3	-142,9	22,4	-220,2
StudentServices	-127,8	47,4	-256,8	-51,2	-127,8	47,4	-256,8
BioEngineeringPV	7,2	10,8	0,0	39,8	7,2	10,8	0,1
CSC BuildingPV	11,8	17,9	0,0	60,4	26,7	18,1	0,0
CUP PV	12,4	18,8	-0,1	71,4	24,2	20,1	-0,1
EBU2 A PV	7,2	10,8	0,0	34,8	7,2	10,8	0,0
EBU2 B PV	5,9	8,8	0,1	29,5	5,9	8,8	0,1
ElectricShopPV	14,7	22,9	-0,1	80,9	14,7	22,9	-0,1
GarageFleetsPV	5,2	7,6	0,0	24,4	5,2	7,6	0,0
HopkinsParkingPV	54,4	83,0	-0,7	296,2	54,4	83,0	-0,7
KyoceraSkylinePV	0,9	1,3	0,0	5,1	1,7	1,4	0,0
LeichtagPV	6,7	10,8	0,0	45,1	10,8	12,0	0,0
MayerHallPV	25,2	38,6	-0,6	152,6	50,1	41,3	-0,6
MESOM PV	10,1	15,4	-2,9	56,3	10,1	15,4	-2,9
PriceCenterA PV	5,4	7,9	0,0	25,6	5,4	7,9	0,1
PriceCenterB PV	21,8	32,9	-0,9	115,8	44,1	34,8	-0,9
SDSC PV	10,4	15,9	0,0	59,3	20,7	17,0	0,0
SME SolarPV	22,1	32,7	-0,7	113,9	22,1	32,7	-0,7
StephenBirchPV	7,8	11,6	0,0	43,6	7,8	11,6	0,1

* без урахування нульових значень

Генерація СЕС, навпаки, має найбільшу відносну змінність: середнє значення близько 230 кВт супроводжується стандартним відхиленням такого самого порядку, що відображає різкі добові піки, нульові нічні значення та вплив погодних факторів. Індивідуальні будівлі показують значно стабільніший характер: їхні середні навантаження коливаються від кількох десятків до кількох сотень кіловат, водночас варіативність істотно нижча за середній рівень. Особливо стабільними є невеликі будівлі на кшталт Hopkins чи PoliceDepartment, тоді як найбільше навантаження демонструє GeiselLibrary.

У підсумку портфель із 27 об'єктів – 17 СЕС і 10 будівель – поєднує регулярну поведінку споживання та стохастичність генерації, що зумовлює складну структуру сумарних рядів і пояснює відмінності в точності прогнозування для різних підходів до агрегації.

Дані характеризуються наявністю добової та тижневої сезонності, нерівномірністю в номінальній потужності, відсутністю повної кореляції між будівлями, а також характерною для PV різкою асиметрією та великою часткою нульових значень у нічні години. Саме така

структура робить набір придатним для порівняння трьох рівнів агрегації: повністю агрегованого прогнозу сумарного ряду, частково агрегованого прогнозування (споживання та генерація окремо) та дезагрегованого прогнозування із наступною агрегацією.

Попередня обробка включала усунення локальних аномалій та нормування вхідних даних у межах $[0;1]$ окремо для кожного об'єкта. Для PV-генерації збережено нульові значення, оскільки вони є фізично обґрунтованими та визначають розподіл похибок моделей.

Модель Transformer для прогнозування часових рядів. Для всіх експериментальних сценаріїв використовувалася однофакторна модель на основі моделі Transformer [14], реалізована як послідовність блоків Multi-Head Attention та Feed-Forward із позиційним кодуванням. Модель реалізує відображення з фіксованого вікна попередніх значень часового ряду до скалярного прогнозу на один крок уперед. Ключовим елементом трансформера є шар багатоголової самоуваги (multi-head self-attention), який дає змогу моделі одночасно враховувати взаємодію між усіма моментами часу всередині вікна.

Розрахунки реалізовано в середовищі Python 3.14 із використанням бібліотек PyTorch для моделювання нейронних мереж та Scikit-learn для попередньої обробки даних. План експерименту забезпечував можливість порівняння трьох підходів: для всіх моделей використовувалося однакове розділення вибірки на навчальну (80%), валідаційну (10%) та тестову (10%) частини, фіксоване вікно авторегресії (48 попередніх годин для прогнозу на один крок уперед) та єдині правила масштабування вихідних величин. Навчання здійснювалося на CPU із прискоренням завдяки паралельному запуску окремих процесів для кожного об'єкта, що дало змогу збільшити кількість моделей у bottom-up підході без значної втрати продуктивності. Для кожної моделі використовувався критерій раннього зупинення за найменшим значенням помилки (MSE) на валідаційному наборі даних, що забезпечувало уникнення перенавчання.

Рішення щодо однакової моделі для всіх рівнів агрегації було прийнято для того, щоб відокремити вплив структури даних (агрегації) від впливу конкретної архітектури. Отже, у кожній із трьох стратегій змінювався лише вхідний ряд (агрегований, частково агрегований чи дезагрегований), тоді як модель залишалася сталою.

Агреговані показники для bottom-up та частково агрегованого підходів формувалися як алгебраїчна сума відповідних прогнозів (наприклад, Total_dis_Pred як сума всіх прогнозів, Total_part_Pred як сума прогнозів Total_Consumption_Pred і Total_PV_Pred). Такий підхід дав змогу виділити вплив накопичення похибок, що є ключовим фактором у bottom-up стратегії.

Оцінка похибки прогнозу. Для порівняння якості моделей на тестовій вибірці використовувались нормовані відносні метрики MAPE та NRMSE щодо середнього значення часового ряду за модулем.

Таке визначення NRMSE дає змогу інтерпретувати метрику як відносну середньоквадратичну похибку у відсотках від середнього рівня досліджуваного ряду. Застосування пари метрик MAPE/NRMSE є доцільним, оскільки MAPE є більш чутливою до помилок за малих значень U_t , тоді як NRMSE описує загальний рівень похибки моделі.

Результати. Отримані результати демонструють чітку залежність точності прогнозування від рівня агрегації, що узгоджується з висновками, наведеними в огляді джерел. Значення показників похибки прогнозу наведено в таблиці 2.

Для прогнозування сумарного нетто-навантаження часткова агрегація виявилася найточнішою (рис. 1): MAPE приблизно 4,3% проти 4,8% у прямого агрегованого прогнозу. Дезагреговане прогнозування суттєво поступається, демонструючи MAPE понад 6,5% та збільшений NRMSE. Такі результати є типовими для bottom-up моделей, де навіть невеликі відхилення окремих прогнозів накопичуються, збільшуючи сумарну похибку.

Таблиця 2

Прогноз*	MAPE, %	NRMSE, %
Total_agg	4,81	-6,09
Total_part	4,34	-5,76
Total_dis	6,54	-7,41
Total_Consumption_agg	2,30	-3,00
Total_Consumption_dis	1,92	-2,57
Total_PV_agg	661,98	27,67
Total_PV_dis	971,07	44,11

* agg – агрегований підхід, part – часткова агрегація, dis – дезагрегований підхід

Для споживання агрегований (рис. 2) і частково агрегований підходи (рис. 3) показали високий рівень точності: MAPE для сумарного споживання становила приблизно 2...2,5 %, NRMSE – 2,5...3 %, тоді як дезагреговані прогнози після підсумовування забезпечили трохи кращу MAPE (порядку 1,9 %), але водночас мали збільшений систематичний зсув. Це свідчить про узгодженість окремих моделей на рівні будівель, проте виявляє відносну нестабільність агрегованої оцінки.

Найскладнішим об'єктом для прогнозування виявилася PV-генерація: унаслідок великої кількості нульових значень MAPE набував аномально великих значень (понад 600...900 % навіть для агрегованих рядів). Водночас NRMSE залишався на рівні 25...40 %, що відображає реальну якість прогнозу значно точніше. Проте навіть за NRMSE агреговане прогнозування випереджає дезагрегований підхід (рис. 4), зберігаючи більшу стабільність і менший систематичний зсув.

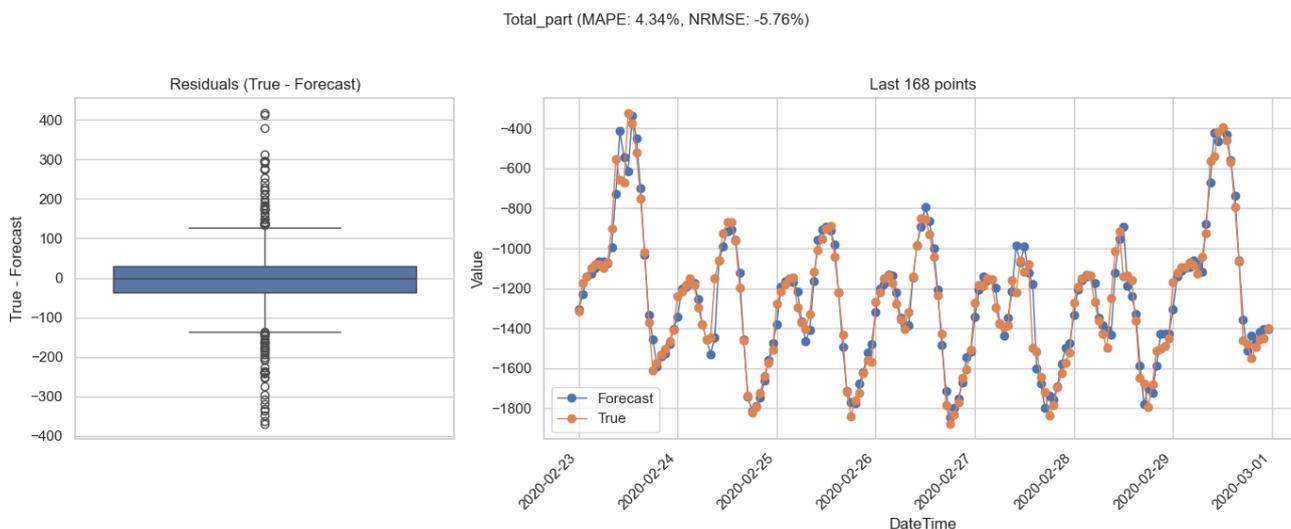


Рис. 1. Прогнозування нетто-навантаження шляхом часткової агрегації.
(1) Вох-plot розподілу похибки прогнозу, (2) фактичні та прогнозні значення

Аналіз добових профілів похибок показує типову систематичну поведінку моделей, вони схильні недооцінювати вечірні піки споживання приблизно між 18:00 та 22:00 і водночас переоцінювати навантаження у ранкові години від 6:00 до 9:00. Такі зсуви відтворюються майже щоденно, що свідчить про неповне охоплення добової сезонності трансформером, обмеженим 48-годинним вікном спостереження. Через це модель добре відтворює локальні закономірності, але втрачає контекст зміни структури навантаження між окремими днями тижня.

Особливість характеру помилок генерації СЕС проявляється в тому, що ранкові години часто супроводжуються випередженням прогнозів, коли фактичні значення з'являються на одну-дві години пізніше, моделі схильні згладжувати денні піки. Це типовий результат прогнозування без урахування метеорологічних даних.

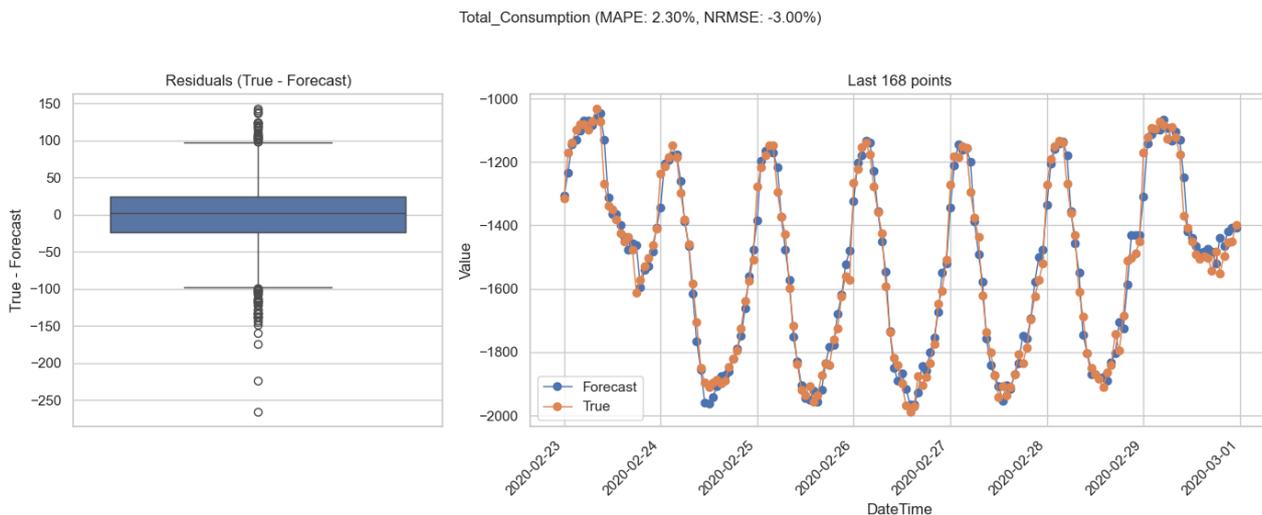


Рис. 2. Агреговане прогнозування сумарного споживання.
(1) Вох-plot розподілу похибки прогнозу, (2) фактичні та прогнозні значення

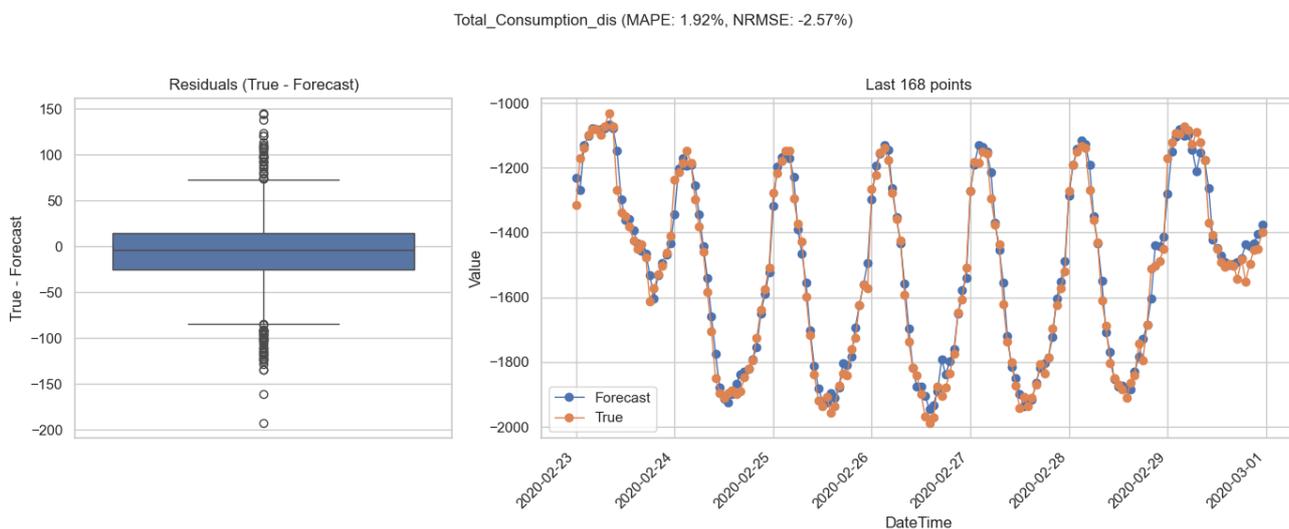


Рис. 3. Дезагреговане прогнозування сумарного споживання.
(1) Вох-plot розподілу похибки прогнозу, (2) фактичні та прогнозні значення

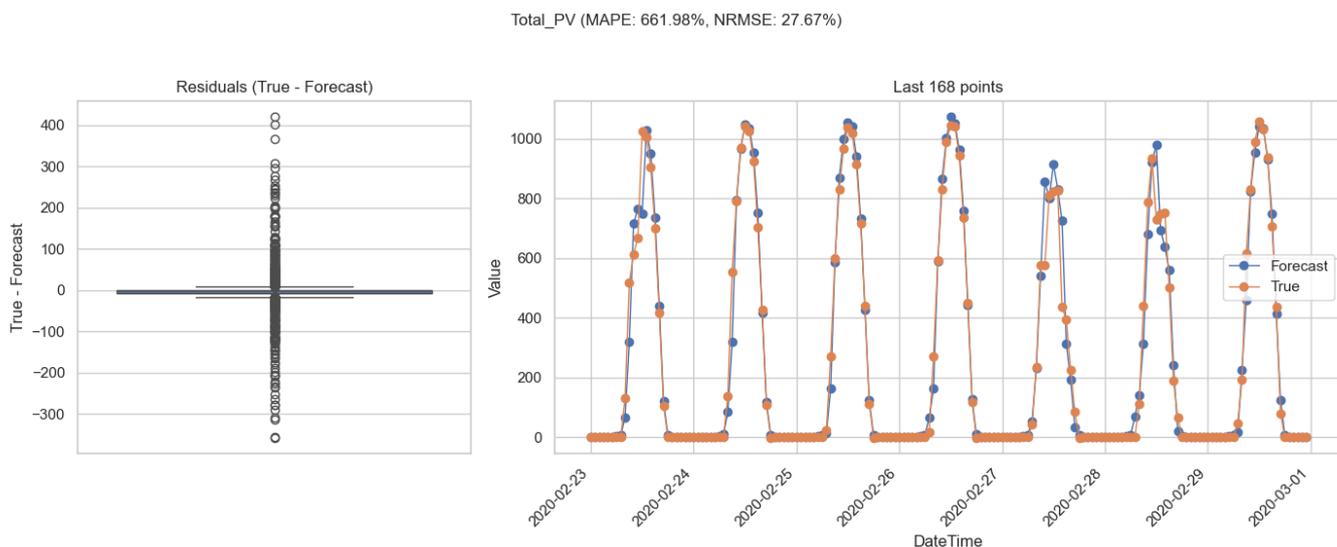


Рис. 4. Дезагреговане прогнозування сумарної генерації.
(1) Вох-plot розподілу похибки прогнозу, (2) фактичні та прогнозні значення

Структурна природа похибок зумовлена обмеженнями однофакторної моделі трансформерного типу. Фіксоване вікно тривалістю 48 годин не охоплює довготривалих закономірностей, зокрема змін у поведінці у вихідні дні чи за сезонних коливань. Відсутність додаткових предикторів, наприклад, метеорологічних даних для СЕС або календарних ознак для будівель позбавляє модель необхідної гнучкості.

Висновки. Проведене дослідження підтвердило принципову залежність точності короткострокового прогнозування від рівня агрегації часових рядів у структурі віртуального об'єднання. Отримані результати свідчать про те, що для навантаження (споживання) найвищу точність забезпечує дезагреговане прогнозування із наступною агрегацією. Це означає, що для навантажень будівель індивідуальні часові ряди динамічно узгоджені, а накопичення похибок при агрегуванні залишається незначним. Такий результат є важливим для задач керування попитом та локальної оптимізації, де поведінка окремих об'єктів суттєво впливає на структуру сумарного профілю.

Для прогнозування сумарного нетто-навантаження картина є іншою: частково агрегований підхід продемонстрував найкращий баланс між точністю та стабільністю. Це узгоджується з висновками попередніх робіт щодо переваги часткової агрегації у випадках, коли компоненти (споживання та генерація) мають різну природу та різні драйвери змінності, і підтверджує доцільність роздільного моделювання портфеля навантаження та портфеля ВДЕ.

Окремо слід відзначити результати для сонячної генерації. Сукупні показники свідчать про те, що як пряме агреговане прогнозування PV, так і дезагреговане суттєво поступаються точності моделей навантаження.

Узагальнюючи результати, можна сформулювати такі ключові положення щодо придатності підходів до прогнозування у контексті віртуальних об'єднань:

1. Для навантаження непобутових споживачів дезагреговане прогнозування є найбільш точним і забезпечує найменше значення як MAPE, так і NRMSE.
2. Для сумарного нетто-навантаження оптимальним підходом є часткова агрегація, яка мінімізує сумарну похибку завдяки окремому моделюванню споживання та PV-генерації.
3. Для генерації СЕС усі три підходи демонструють підвищену чутливість до структурних особливостей даних; MAPE виявляється неінформативною, а NRMSE засвідчує необхідність використання спеціалізованих моделей із метеорологічними предикторами.

Отже, результати дослідження підтверджують, що вибір рівня агрегації має критичне значення для точності оперативного прогнозування у віртуальних об'єднаннях, а комбінована стратегія з окремим моделюванням споживання й генерації є найбільш ефективною для портфелів, де присутня суттєва частка ВДЕ.

Фінансується за держбюджетною темою «Розвиток розподіленої енергетики в умовах ринку електричної енергії України з використанням технологій та систем цифровізації. Розділ 1. Організаційні та математичні моделі взаємодії учасників децентралізованого ринку електроенергії» (шифр. Цифровізація) (КПКВК 6541230).

1. Кириленко О.В., Денисюк С.П., Блінов І.В. Цифрова трансформація: сучасні тенденції та завдання. *Праці Інституту електродинаміки Національної академії наук України*. 2023. Вип. 65. С. 5–14. DOI: <https://doi.org/10.15407/publishing2023.65.005>
2. Блінов І., Парус Є., Шиманюк П. і Ворущило А. Модель оптимізації функціонування мікромережі з СЕС та установкою зберігання енергії. *Технічна електродинаміка*. 2024. № 5. С. 69–78. DOI: <https://doi.org/10.15407/techmed2024.05.069>
3. Парус Є.В., Блінов І.В. Оптимізація використання доступних енергоресурсів мікромережі за умов підтримки готовності до ізольованого режиму. *Технічна електродинаміка*. 2025. № 5. С. 56–69. DOI: <https://doi.org/10.15407/techmed2025.05.056>.
4. Белоха Г. С., & Сичова В. В. Оптимізація графіків електричного навантаження агрегатором у локальних електроенергетичних системах. *Праці Інституту електродинаміки НАН України*. 2023, № 66. С. 84–89. DOI: <https://doi.org/10.15407/publishing2023.66.084>
5. Blinov I., Radziukynas V., Shymaniuk P., Dyczko A., Stecula K., Sychova V., Miroshnyk V., & Dychkovskyi R. Smart management of energy losses in distribution networks using deep neural networks. *Energies*, 2025. No 18. Pp. 3156. DOI: <https://doi.org/10.3390/en18123156>

6. Черненко П.О., Мартинюк О.В., & Мірошник В.О. Моделювання та короткострокове прогнозування технологічної складової електричного навантаження обласної енергосистеми. *Технічна електродинаміка*, 2016. No 4. Pp. 68–70.
7. Peñaloza A. A., Leborgne R. C., & Balbinot A. Comparative analysis of residential load forecasting with different levels of aggregation. *Engineering Proceedings*. 2022. No 18(1). Pp. 29. DOI: <https://doi.org/10.3390/engproc2022018029>
8. Beichter M., Phipps K., Frysztacki M. M., Mikut R., Hagemeyer V., & Ludwig N. Net load forecasting using different aggregation levels. *Energy Informatics*. 2022, No 5(S1). Pp. 19. DOI: <https://doi.org/10.1186/s42162-022-00213-8>
9. Peng Y., Wang Y., Lu X., Li H., Shi D., Wang Z., & Li J. Short-term load forecasting at different aggregation levels with predictability analysis. *IEEE Innovative Smart Grid Technologies – Asia (ISGT Asia)*. 2019. Pp. 3385–3390. DOI: <https://doi.org/10.1109/ISGT-Asia.2019.8881343>
10. Sevlian R., & Rajagopal R. Short term electricity load forecasting on varying levels of aggregation. *arXiv preprint*. 2017. arXiv:1404.0058.
11. Anand H., Nateghi R., & Alemazkooor N. Bottom-up forecasting: Applications and limitations in load forecasting using smart-meter data. *Data-Centric Engineering*. 2023. No 4. Pp. e14. DOI: <https://doi.org/10.1017/dce.2023.10>
12. Bandyopadhyay S., Ganu T., Khadilkar H., & Arya V. Individual and aggregate electrical load forecasting: One for all and all for one. In *Proceedings of the 6th International Conference on Future Energy Systems, e-Energy '15*. Pp. 257–267. DOI: <https://doi.org/10.1145/2768510.2768539>
13. S. Silwal, C. Mullican, Y.-A. Chen, A. Ghosh, J. Dilliot, and J. Kleissl, Open-source multi-year power generation, consumption, and storage data in a microgrid, *Journal of Renewable and Sustainable Energy*. 2021. Vol. 13. No. 2. Pp. 025301. DOI: <https://doi.org/10.1063/5.0038650>
14. Vaswani A. *et al.* Attention is all you need, I. Guyon, U. Von Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan, and R. Garnett, Eds., Curran Associates, Inc., In Proceedings of the 31st International Conference on Neural Information Processing Systems (NIPS'17). Curran Associates Inc., Red Hook, NY, USA, 6000–6010.

COMPARISON OF NET-LOAD FORECASTING APPROACHES FOR VIRTUAL AGGREGATIONS OF ENERGY FACILITIES

V. Miroshnyk, V. Sychova

Institute of Electrodynamics of the National Academy of Sciences of Ukraine,
Beresteyskiy ave., 56, Kyiv, 03057, Ukraine
e-mail: miroshnyk.volodymyr@gmail.com, shorl@ukr.net

This study presents a comparative evaluation of three approaches to short-term net-load forecasting for virtual aggregations of heterogeneous energy facilities, comprising both building loads and photovoltaic units. The objective is to assess how different levels of data aggregation influence the forecasting accuracy of total consumption, PV generation, and the resulting net load. All experiments were conducted on the UCSD Microgrid dataset using an identical Transformer-based model, which allowed isolating the effect of data structure rather than model architecture. The results show that disaggregated bottom-up modelling yields the highest accuracy for building consumption, whereas partial aggregation—separate forecasting of total load and PV generation—provides the best performance for net-load prediction. PV generation remains the most challenging component due to structural asymmetry and extended zero-generation intervals; in this case, aggregated forecasts demonstrate lower energy error compared to bottom-up models. The findings provide practical guidance for selecting appropriate aggregation schemes and forecasting strategies in virtual power plants and emerging local energy markets. Ref. 14, fig. 4.

Keywords: short-term load forecasting, aggregators, local electricity markets, neural networks, virtual power plants

1. Kyrylenko O., Denysiuk S., Blinov I. Digital transformation of the energy industry: current trends and task. *Pratsi Instytutu Elektrodynamiky NAN Ukrainy*. 2022. V. 65. Pp. 5–14. (Ukr) DOI: <https://doi.org/10.15407/publishing2022.65.005>
2. Blinov I.V., Parus Ye.V., Shymaniuk P.V., Vorushylo A.O.. 2024. Optimization model of microgrid functioning with solar power plant and energy storage system. *Tekhnichna Elektrodynamika*. 2024. No 5. Pp. 69–78. DOI: <https://doi.org/10.15407/techned2024.05.069>
3. Parus Ye.V., Blinov I.V. Optimization of the use of available energy resources of the microgrid under the condition of supporting readiness for isolated mode. *Tekhnichna Elektrodynamika*. 2025. No 5. Pp. 56–69. DOI: <https://doi.org/10.15407/techned2025.05.056>
4. Belokha H.S., Sychova V.V. Optimization of electric load schedules by an aggregator in local power systems. *Pratsi Instytutu Elektrodynamiky NAN Ukrainy*, 2023. No 66. Pp. 84–89. DOI: <https://doi.org/10.15407/publishing2023.66.084>

5. Blinov I., Radziukynas V., Shymaniuk P., Dyczko A., Stecula K., Sychova V., Miroshnyk V., & Dychkovskiy R. Smart management of energy losses in distribution networks using deep neural networks. *Energie.*, 2025, No 18. Pp. 3156. DOI: <https://doi.org/10.3390/en18123156>
6. Chernenko P.O., Martyniuk O.V., & Miroshnyk V.O. Modelling and short-term forecasting of the technological component of the electrical load of a regional power system. *Tekhnichna Elektrodynamika.* 2016. No 4. Pp. 68–70.
7. Peñaloza A. A., Leborgne R. C., & Balbinot A. Comparative analysis of residential load forecasting with different levels of aggregation. *Engineering Proceedings.* 2022., No 18(1). Pp. 29. DOI: <https://doi.org/10.3390/engproc2022018029>
8. Beichter M., Phipps K., Frysztacki M. M., Mikut R., Hagenmeyer V., & Ludwig N. Net load forecasting using different aggregation levels. *Energy Informatics.* 2022, No 5(S1). Pp. 19. DOI: <https://doi.org/10.1186/s42162-022-00213-8>
9. Peng Y., Wang Y., Lu X., Li H., Shi D., Wang Z., & Li J. Short-term load forecasting at different aggregation levels with predictability analysis. *IEEE Innovative Smart Grid Technologies – Asia (ISGT Asia) 2019.* Pp. 3385–3390. DOI: <https://doi.org/10.1109/ISGT-Asia.2019.8881343>
10. Sevlian R., & Rajagopal R. Short term electricity load forecasting on varying levels of aggregation. *arXiv preprint.* 2017. arXiv:1404.0058.
11. Anand H., Nateghi R., & Alemazkour N. Bottom-up forecasting: Applications and limitations in load forecasting using smart-meter data. *Data-Centric Engineering,* 2023. No 4. Pp. e14. DOI: <https://doi.org/10.1017/dce.2023.10>
12. Bandyopadhyay S., Ganu T., Khadilkar H., & Arya V. Individual and aggregate electrical load forecasting: One for all and all for one. *Proceedings of the 6th International Conference on Future Energy Systems (e-Energy '15).* Pp. 257–267 DOI: <https://doi.org/10.1145/2768510.2768539>
13. Silwal S., Mullican C., Chen Y.A., Ghosh A., Dilliot J., and Kleissl J. Open-source multi-year power generation, consumption, and storage data in a microgrid, *Journal of Renewable and Sustainable Energy.* 2021. Vol. 13. No. 2. Pp. 025301. DOI: <https://doi.org/10.1063/5.0038650>.
14. Vaswani A. *et al.* Attention is all you need, I. Guyon, U. Von Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan, and R. Garnett, Eds., Curran Associates, Inc., In Proceedings of the 31st International Conference on Neural Information Processing Systems (NIPS'17). Curran Associates Inc., Red Hook, NY, USA, 6000–6010.

Надійшла: 25.11.2025

Прийнята: 02.12.2025

Submitted: 25.11.2025

Accepted: 02.12.2025