

Міністерство освіти і науки України
Харківський національний університет радіоелектроніки

Факультет Комп'ютерних наук
(повна назва)

Кафедра Штучного інтелекту
(повна назва)

КВАЛІФІКАЦІЙНА РОБОТА
Пояснювальна записка

рівень вищої освіти другий (магістерський)

Порівняльний аналіз методів прогнозування часових рядів для
ефективного використання електроенергії
(тема)

Виконав:
студент 2 курсу, групи СШМ-22-1
Сумець С.І.
(прізвище, ініціали)

Спеціальність 122 Комп'ютерні науки
(код і повна назва спеціальності)

Тип програми освітньо-наукова
(освітньо-професійна або освітньо-наукова)

Освітня програма Системи штучного інтелекту
(повна назва спеціалізації)

Керівник доц. Чала Л.Е.
(посада, прізвище, ініціали)

Допускається до захисту

Зав. кафедри _____
(підпис)

В.О. Філатов
(прізвище, ініціали)

2024 р.

Харківський національний університет радіоелектроніки

Факультет Комп'ютерних наук
(повна назва)
Кафедра Штучного інтелекту
(повна назва)
Рівень вищої освіти другий (магістерський)
Спеціальність 122 Комп'ютерні науки
(код і повна назва)
Тип програми освітньо-наукова
(освітньо-професійна або освітньо-наукова)
Освітня програма Системи штучного інтелекту
(повна назва)

ЗАТВЕРДЖУЮ:
Зав. кафедри _____
(підпис)
«_____» _____ 20__ р.

ЗАВДАННЯ
НА КВАЛІФІКАЦІЙНУ РОБОТУ

студентові Сумець Світлані Ігорівні
(прізвище, ім'я, по батькові)

1. Тема роботи Порівняльний аналіз методів прогнозування часових рядів для ефективного використання електроенергії

затверджена наказом університету від 1 квітня 20 24 р. № 260Ст

2. Термін подання студентом роботи до екзаменаційної комісії 12 червня 20 24 р.

3. Вихідні дані до роботи Література про прогнозування часових рядів, література про методи прогнозування, методи ARIMA, ARIMAX, SARIMA, SARIMAX, DeepAR, Prophet

4. Перелік питань, що потрібно опрацювати в роботі _____

1) Аналіз предметної області та постановка задачі, вибір і обґрунтування методів прогнозування часових рядів

2) Проведення експериментальних практичних досліджень в контексті постачання електроенергії

РЕФЕРАТ

Пояснювальна записка: 119 с., 38 рис., 1 табл., 2 дод., 10 джерел.

АНАЛІЗ ДАНИХ, МАШИННЕ НАВЧАННЯ, МОДЕЛЬ, НЕЙРОННІ МЕРЕЖІ, ПРОГНОЗУВАННЯ, ЧАСОВІ РЯДИ, ARIMA, ARIMAX, DEEPAR, PROPNET, SARIMA, SARIMAX.

Мета роботи – дослідження методів прогнозування часових рядів з використанням машинного навчання на прикладі завдань постачання електроенергії.

Об'єкт дослідження – методи прогнозування часових рядів з використанням машинного навчання.

Предмет дослідження – порівняльний аналіз інтелектуальних методів прогнозування часових рядів в завданнях постачання електроенергії.

Методи дослідження – методи оцінювання якості прогнозуючих моделей; методи експериментального моделювання процесів прогнозування часових рядів.

Мета роботи полягає в аналізі та порівнянні ефективності різних методів прогнозування часових рядів для передбачення споживання електроенергії в умовах надзвичайних ситуацій, зокрема під час війни в Україні та після пошкодження електростанцій внаслідок терористичних актів. Отримані результати мають допомогти в управлінні та кращому розподілі електричної енергії між споживачами у критичні моменти.

Методи дослідження – аналіз літератури, інтернет джерел, технічної документації та інструментарію для роботи з часовими рядами.

У ході виконання даної роботи був проведений аналіз та порівняння методів ARIMA, ARIMAX, SARIMA, SARIMAX, Prophet, DeepAR, що використовуються для прогнозування часових рядів.

ABSTRACT

Master's thesis contains: 119 p., 38 fig., 1 tabl., 2 ann., 10 references.

ANALYSIS, MACHINE LEARNING, MODEL, NEURAL NETWORKS, FORECASTING, TIME SERIES, ARIMA, ARIMAX, DEEPAR, PROPHET, SARIMA, SARIMAX.

The purpose of the study is to investigate the methods of time series forecasting using machine learning on the example of electricity supply tasks.

Object of study – methods of time series forecasting using machine learning.

The subject of the study is a comparative analysis of intelligent methods for forecasting time series in electricity supply tasks.

Research methods – methods for assessing the quality of forecasting models; methods of experimental modeling of time series forecasting processes.

The purpose of the study is to analyze and compare the effectiveness of various time series forecasting methods for predicting electricity consumption in emergency situations, in particular during the war in Ukraine and after damage to power plants as a result of terrorist attacks. The results should help in managing and better distributing electricity among consumers at critical times.

Research methods: analysis of literature, Internet sources, technical documentation and tools for working with time series.

In the course of this work, we analyzed and compared the ARIMA, ARIMAX, SARIMA, SARIMAX, Prophet, DeepAR methods used for time series forecasting.

ЗМІСТ

Перелік умовних позначень, символів, одиниць, скорочень і термінів	8
Вступ.....	9
1 Аналіз предметної галузі та постановка задачі.....	10
1.1 Опис предметної галузі	10
1.1.1 Основні концепції часових рядів.....	10
1.1.2 Аналіз часових рядів.....	12
1.1.3 Прогнозування як процес передбачення	17
1.2 Аналіз методів машинного навчання для прогнозування.....	19
1.2.1 Теоретичні аспекти методів машинного навчання, які використовуються для прогнозування.....	19
1.2.2 Застосування методів машинного навчання до задач прогнозування часових рядів	22
1.3 Актуальність, новизна та можливе застосування	23
1.4 Постановка задачі.....	25
2 Теоретичний огляд методів прогнозування часових рядів.....	26
2.1 Метод ARIMA	26
3.2 Метод ARIMAX	30
3.3 Метод SARIMA	34
2.4 Метод SARIMAX	37
3.5 Метод DeepAR.....	40
2.6 Метод Prophet	44
3 Практичне дослідження методів прогнозування часових рядів.....	46
3.1 Дані та підготовка до дослідження	46
3.2 ARIMA.....	53
3.3 ARIMAX.....	59
3.4 SARIMA	65
3.5 SARIMAX	70
3.6 DeepAR.....	75

3.7 Prophet	78
4 Ансамблі моделей прогнозування часових рядів	86
4.1 Ансамблювання моделей як спосіб покращити точність	86
4.2 Ансамблювання моделей методом бустингу	88
4.3 Ансамблювання моделей методом голосування.....	92
4.4 Ансамблювання моделей методом бегінгу	94
Висновки	98
Перелік джерел посилання	99
Додаток А Графіки результатів дослідження.....	100
Додаток Б Відомість кваліфікаційної роботи.....	119

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ І ТЕРМІНІВ

ACF – Autocorrelation Function – функція автокореляції;

AR – autoregressive – авторегресія;

ARIMA – Autoregressive Integrated Moving Average – авторегресія з інтегрованим рухомим середнім;

ARIMAX – Autoregressive Integrated Moving Average with Explanatory Variables – авторегресія з інтегрованим рухомим середнім з пояснювальними змінними;

ETS – Error-Trend-Seasonality – помилка, тренд, сезонність;

GRU – Gated Recurrent Unit – вентильний рекурентний блок;

KPSS – Kwiatkowski-Phillips-Schmidt-Shin Test – тест Квіатковського-Філіпса-Шмідта-Шіна;

LASSO – Least Absolute Shrinkage and Selection Operator – оператор найменших абсолютних зсувів і вибору;

LSTM – Long Short-Term Memory – довга короткострокова пам'ять;

MA – Moving Average – ковзне середнє;

MAE – Mean Absolute Error – середня абсолютна похибка;

PACF – Partial Autocorrelation Function – часткова автокореляційна функція;

PCA – Principal Component Analysis – аналіз головних компонент;

RNN – Recurrent Neural Network – рекурентна нейронна мережа;

RMSE – Root Mean Squared Error – квадратний корінь середньої квадратичної похибки;

SARIMA – Seasonal Autoregressive Integrated Moving Average – сезонна авторегресія з інтегрованим рухомим середнім;

SARIMAX – Seasonal Autoregressive Integrated Moving Average with Explanatory Variables – сезонна авторегресія з інтегрованим рухомим середнім з пояснювальними змінними.

ВСТУП

Із появою новітніх технологій та розвитком інформаційного суспільства важливість аналізу та прогнозування стала надзвичайно актуальною. Предметною областю дослідження є прогнозування постачання електропостачання, ця тема є особливо актуальною в сьогоденних реаліях. У сучасному світі, де електроенергія відіграє ключову роль у забезпеченні життєвих потреб людей та функціонуванні промислових підприємств, точне прогнозування споживання електроенергії є критично суттєвим завданням.

Аналіз та прогнозування часових рядів є одним із основних методів для передбачення споживання електроенергії. Використання різноманітних моделей, таких як ARIMA, SARIMA тощо, дозволяє здійснювати прогнози з високою точністю. Перевага використання машинного навчання полягає у здатності моделей адаптуватися до змін у даних та забезпеченні більш точних прогнозів у складних умовах.

Прогнозування споживання електроенергії має велике значення у вирішенні нагальних проблем, таких як оптимізація розподілу електроенергії у часи кризових ситуацій, наприклад, під час війни або надзвичайних обставин. Точні прогнози дозволять ефективно керувати електромережами, забезпечуючи найважливіші об'єкти енергією в першу чергу.

Отже, об'єкт дослідження – методи прогнозування часових рядів з використанням машинного навчання.

Мета роботи – дослідження методів прогнозування часових рядів з використанням машинного навчання на прикладі завдань постачання електроенергії.

1 АНАЛІЗ ПРЕДМЕТНОЇ ГАЛУЗІ ТА ПОСТАНОВКА ЗАДАЧІ

1.1 Опис предметної галузі

1.1.1 Основні концепції часових рядів

Часовий ряд представляє собою упорядкований набір даних, де кожне значення пов'язане з конкретним моментом часу. Часовий ряд можна побудувати з будь-якої змінної, яка змінює своє значення з часом.

Це значний інструмент для вивчення динаміки явищ та змін параметрів протягом тривалого періоду. Такі ряди використовуються у різних галузях, включаючи економіку, науку, техніку та соціальні дослідження.

На відміну від часового ряду, звичайний набір даних навпаки може бути представлений без чітко визначеного часового контексту. Він може включати різні атрибути чи ознаки, але відсутня явна залежність від часу. Такі дані можуть бути статичними та не зазнають часових змін.

Основна відмінність полягає в тому, що часовий ряд дозволяє вивчати динаміку явища в залежності від часу, тоді як звичайний набір даних не враховує цього часового аспекту.

Складові часового ряду допомагають розкласти його на різні частини з метою кращого розуміння й прогнозування. Основні складові часового ряду включають тренд, сезонність, циклічність, випадкова складова.

Тренд у часовому ряді є основною та довгостроковою тенденцією зміни значень вздовж часу. Визначення тренду дозволяє виявляти загальні напрямки та рухи даних.

Зростаючий тренд свідчить про систематичне збільшення значень часового ряду з плином часу. Це може вказувати на позитивні тенденції, такі як економічний ріст або зростання попиту на певний продукт. З іншого боку, спадаючий тренд вказує на систематичне зменшення значень, що може

свідчити про економічний спад чи зменшення інтересу до конкретної послуги.

Щоб визначити тренд у часовому ряді, можна використовувати різні методи, такі як рухомі середні, лінійна апроксимація чи експоненційне згладжування. Після виявлення тренду, аналіз його характеристик допомагає розуміти основні тенденції та прогнозувати майбутні зміни в часовому ряді.

Сезонність у часовому ряді відображає систематичні та повторювані коливання в даних, які пов'язані із змінами вздовж фіксованого періоду часу. Ці періодичні коливання можуть бути пов'язані з природними явищами, соціокультурними факторами чи іншими циклічними подіями.

Наприклад, у продажів різноманітних товарів може бути сезонність, де певні товари чи послуги більш популярні або затребувані в певний період року. Наприклад, продаж вентиляторів та кондиціонерів може бути вищим влітку, а продажі обігрівачів – взимку.

Циклічність у часовому ряді відображає довгострокові зміни, які не повторюються з фіксованою періодичністю, як сезонні коливання. Ці коливання можуть мати різну тривалість і не завжди пов'язані з якимось конкретним періодом, як у випадку сезонності.

Випадкова складова у часовому ряді представляє собою невинуваті, неперіодичні та непрогнозовані відхилення від тренду та сезонності. Це коливання в даних, які не можна пояснити систематичними закономірностями чи циклічними впливами. Випадкова складова визначається випадковими подіями та факторами, які не можна передбачити чи контролювати.

Наприклад, випадкові волатильності цін на фондовому ринку, несподівані зміни споживчого попиту через зовнішні фактори, такі як екологічні катастрофи або політичні події, можуть внести непередбачувані коливання у часовий ряд.

Розуміння випадкової складової допомагає аналізувати невизначеність та ризики, які можуть впливати на часовий ряд. Це суттєво для прийняття обґрунтованих рішень та розробки надійних прогнозів у контексті невизначеності в економіці, фінансах та інших галузях.

Компоненти часових рядів схематично представлені на рисунку 1.1.




Рисунок 1.1 – Компоненти часових рядів

1.1.2 Аналіз часових рядів

Аналіз часових рядів – це метод вивчення послідовностей даних, організованих у порядку їхнього виникнення в часі. Основна мета цього виду аналізу полягає в розкритті закономірностей та характеристик, які можуть бути приховані у динаміці часових показників.

Однією з основних задач аналізу часових рядів є прогнозування. Шляхом вивчення минулих даних та їхніх змін у часі можна розробити моделі, що дозволяють передбачати майбутні значення. Це особливо

необхідно для бізнесу та економіки, де можливість передбачення майбутніх тенденцій допомагає в управлінні ресурсами та прийнятті ефективних рішень.

Застосування аналізу часових рядів розповсюджується на різні галузі, включаючи фінанси, а саме прогнозування цін на акції, метеорологію, виробництво тощо. Він допомагає виявляти регулярності в даних, що є важливим етапом для кращого розуміння та прийняття обґрунтованих управлінських рішень.

Аналіз часових рядів поділяється на дві основні категорії: методи, що працюють в часовому домені, і методи, що опираються на частотний домен. У першому випадку використовуються прямі спостереження за даними з їхнім розвитком. Наприклад, конструюючи графік часового ряду, можна визначити підйоми, падіння та циклічні рухи для подальшого аналізу.

Статистичні методи, такі як ковзні середні, використовуються для згладжування короткострокових коливань і виявлення довгострокових тенденцій та циклів. Автокореляційний аналіз дозволяє вивчати кореляції між послідовними спостереженнями за різними часовими лагами. У методах частотного домену, таких як перетворення Фур'є, використовується розкладання часового ряду на окремі циклічні компоненти з різними частотами.

Аналіз часових рядів включає шість основних етапів. Перший – це підготовка даних, яка є ключовим кроком у вивченні часових рядів. Цей етап включає збір відповідних даних і перевірку їхньої повноти та точності. На цьому етапі вирішуються будь-які відсутні значення чи викиди, і проводиться оцінка стаціонарності даних.

Другий етап – це дослідницький аналіз даних. На цьому етапі використовуються статистичні методи для аналізу тенденцій, сезонності, кореляції та циклічної поведінки даних. Інструменти, такі як графіки часових рядів та функції автокореляції, використовуються для

попереднього вивчення цих характеристик. Також визначаються будь-які незвичайні спостереження або аномалії.

Третій етап – ідентифікація моделі. Після розуміння властивостей даних вибирається найбільш прийнятна модель прогнозування. Тестуються різні типи моделей, такі як AR, MA, ARMA, ARIMA або SARIMA, на основі шаблонів, виявлених під час дослідницького аналізу. Ідентифікація моделі також визначає необхідну кількість термінів і структуру лагів.

Четвертий етап – це модель прогнозування. Після визначення вибрана модель використовується для прогнозування майбутніх значень часових рядів. Модель застосовується до історичних даних для прогнозування на один або декілька періодів вперед, і проводиться оцінка точності прогнозу на тестових даних.

П'ятий етап – обслуговування моделі. Технічне обслуговування моделі включає моніторинг її продуктивності протягом тривалого часу. При появі нових фактичних спостережень модель періодично переоцінюється та оновлюється для забезпечення надійних прогнозів при зміні поведінки чи середовища.

Шостий етап – домени додатків. Останній етап включає застосування вивчених концепцій та розроблених моделей в різних областях застосування, які демонструють залежність від часу. Приклади включають прогнозування попиту, продажів, захворювань тощо. Різноманітність сфер застосування підкреслює широку корисність аналізу часових рядів у наукових і бізнес-дисциплінах, зокрема вимагаючи глибокого розуміння конкретної галузі для ефективного моделювання.

Аналіз часових рядів використовує статистичні методи для обробки даних, які фіксуються протягом рівних часових інтервалів. Основна мета полягає в виявленні значущих закономірностей, створенні пояснювальних моделей та формуванні прогнозів.

Перший етап – це збір спостережень, розподілених рівномірно в часі. Цей розподіл називається частотою дискретизації, і може включати такі

проміжки часу, як рік, квартал, місяць, тиждень, день і годину. Набір даних повинен бути послідовним, а відсутні значення слід обробляти за допомогою методів інтерполяції або імпутації.

Після збору даних проводиться дослідницький аналіз, який включає візуалізацію даних через графіки. Графік часового ряду з відображенням спостережень на осі ординат і часу на осі абсцис допомагає виявити тренди, стрибки, сезонні цикли та аномалії. Статистичні характеристики, такі як середнє значення, дисперсія, автокореляції та спектральна щільність, надають додаткову інформацію для розуміння характеру даних перед моделюванням.

Після пошукового аналізу обирається відповідна модель часових рядів, така як моделі авторегресії, ковзного середнього, ARIMA, регресії та нейронні мережі тощо. Вибір моделі здійснюється на основі характеристик даних та знань про процес генерації даних. Параметри моделі оцінюються на основі даних, зазвичай за допомогою методу найменших квадратів.

Перевірка встановленої моделі включає аналіз залишкових помилок, помилок передбачення та критеріїв інформації, щоб переконатися у відповідності моделі. Після досягнення задовільного рівня продуктивності переглядають специфікацію моделі, а параметри оцінюються знову в разі виявлення недоліків.

З використанням підтвердженої моделі формуються прогнози. Прогнози в межах вибірки робляться на основі історичного набору даних, який використовується для підгонки моделі. Прогнози за межами вибірки використовують модель для передбачення майбутніх значень за межами набору даних для оцінки. Точкові прогнози дають найбільш ймовірний прогноз, тоді як інтервальні прогнози визначають діапазон можливих значень. Зі збільшенням обсягу нових даних прогнози оновлюються через переоцінку параметрів моделі.

Шляхом розробки статистичних моделей, які враховують сезонність, тенденції та шум, з використанням методів декомпозиції, стає можливим

передбачити, як еволюціонуватиме ряд у наступні періоди. Це сприяє прийняттю управлінських рішень щодо запасів, планування виробництва, прогнозування попиту та розподілу ресурсів.

Дослідження також розкриває розуміння циклічних коливань і точно визначає фази піків, спадів та інших переходів. Це усвідомлення допомагає оцінити вплив зовнішніх факторів на вимірюване явище в майбутніх періодах. Моделі часових рядів додатково виявляють автокореляції всередині одного часового ряду через їх взаємодію та взаємозалежність у кількох минулих випадках. Отримані результати допомагають аналізувати ризики та формувати точні прогнози.

Аналіз часових рядів виявляється надзвичайно корисним при опрацюванні часових даних через ряд переваг. Першою перевагою є те, що моделі, такі як ARIMA і експоненціальне згладжування, дозволяють робити прогнози майбутніх значень, що є значним для планування, встановлення цілей та бюджету.

Друга перевага полягає у тому, що моделювання часових рядів допомагає розкрити базові компоненти і фактори, які впливають на зміни в часі, що розширює розуміння динаміки процесу.

По-третє, використання статистичних методів, таких як автокореляція і крос-кореляція, дозволяє кількісно оцінювати взаємозв'язки в часових рядах, тоді як регресійне моделювання розкриває причинно-наслідкові зв'язки з іншими змінними.

Прості лінійні моделі, такі як ARIMA, засновані на припущеннях про стаціонарність, нормальність та гомоскедастичність. Порушення цих припущень може підірвати надійність, що робить моделі машинного навчання більш привабливими через менш суворі вимоги до припущень.

Складні моделі з надмірними параметрами часто переповнюють навчальні дані, обмежуючи їх узагальнення. Регуляризація та перехресна перевірка, можуть допомогти уникнути цього переобладнання.

Дані часових рядів часто нестационарні, що призводить до складнощів у їхньому аналізі та прогнозуванні. Робота з нестационарністю може додатково ускладнювати моделювання.

Часові ряди та їх аналіз використовуються в різних сферах за допомогою статистичних моделей і моделей машинного навчання.

Щоденні закриття акцій протягом багатьох років формують часовий ряд, відображаючи коливання цін і ринкові сили. Аналітики шукають тенденції, нестабільність, сезонність та прогнозні сигнали, використовуючи моделі часових рядів для передбачення майбутніх цін.

Місячні підсумкові продажі компанії складають часовий ряд, що відображає сезонні моделі, тенденції та бізнес-цикли. Декомпозиція часових рядів виділяє компоненти, а моделі ARIMA допомагають передбачити майбутні продажі.

Вимірювання температури, кількості опадів або швидкості вітру зафіксовані за регулярний проміжок часу, утворюючи часовий ряд. Дані про погоду відображають сезонність і тривалі кліматичні цикли, і методи часових рядів використовуються для виявлення закономірностей та прогнозування погодних умов.

Ключові показники, такі як ВВП, безробіття, виробнича активність, споживча впевненість, інфляція та процентні ставки, слідкують за економічним зростанням, рецесіями та бумами. Регресійний аналіз застосовується до цих показників.

Часові ряди від датчиків Інтернету речей, таких як температура, тиск, енергоспоживання чи вібрація, аналізуються для моніторингу стану обладнання, виявлення аномалій і прогнозування можливих збоїв.

1.1.3 Прогнозування як процес передбачення

Прогнозування – це процес підготовки до майбутніх подій або стану системи на основі аналізу даних і використання різних методів. Цей метод

сприяє прийняттю обґрунтованих рішень у ситуаціях неоднозначності. Процедура передбачає аналіз попередньо зібраних даних, застосування різних методів (статистичних моделей, машинного навчання) і може бути використана в таких сферах, як медицина, технології, фінанси чи економіка. Дуже варто враховувати потенційні небезпеки та труднощі, а також використовувати сучасні технології для підвищення точності та ефективності прогнозів.

Методи прогнозування включають різноманітні підходи для визначення та передбачення майбутніх подій, зокрема:

- статистичні методи, аналіз часових рядів дозволяє вивчати та передбачати зміни в часі, такі як економічні показники або ціни на акції. Статистичні моделі можуть використовувати історичні дані для прийняття рішень щодо майбутніх тенденцій:

- методи машинного навчання, вони використовують алгоритми та моделі для вивчення патернів в даних і роблять прогнози на основі цих вивчених знань, методи машинного навчання можуть бути ефективними для складних завдань прогнозування;

- експертні оцінки, залучення експертів у галузі для отримання кваліфікованих прогнозів, експерти можуть надавати цінні інсайти та інформацію, яку важко врахувати іншими методами;

- оптимізаційні методи, вони використовують математичні моделі для максимізації чи мінімізації обраних критеріїв, ці методи можуть бути застосовані для оптимізації ресурсів та планування;

- комбіновані методи, іноді ефективніше використовувати комбінацію різних методів для отримання більш точних та надійних прогнозів.

Кожен метод має свої переваги та обмеження, і вибір конкретного залежить від контексту завдання та доступності даних.

Прогнозування виявляється надзвичайно значуще у різних сферах, де є вирішення завдань з управління та стратегічного планування.

У сфері економіки та фінансів прогнозування використовується для аналізу та передбачення економічного розвитку. Це може включати оцінку тенденцій у рості ВВП, ринкових цін на товари та послуги, а також прогнозування курсів валют та стану фінансових ринків. Здатність точно передбачити економічні та фінансові тенденції є критичною для прийняття обґрунтованих управлінських рішень і уникнення можливих ризиків.

У галузі медицини прогнозування є ефективним інструментом для передбачення розповсюдження захворювань та епідемій. Використання моделей прогнозування дозволяє не тільки розуміти динаміку поширення хвороб, але й приймати запобіжні заходи та ефективно використовувати ресурси системи охорони здоров'я.

У технологічному секторі прогнозування використовується для планування розвитку та визначення стратегій інновацій. Аналіз технологічних тенденцій дозволяє компаніям та науковим установам передбачати напрямки розвитку, що полегшує прийняття рішень щодо інвестицій та ресурсів.

Загалом, прогнозування стає невід'ємною частиною стратегічного управління у різних галузях, дозволяючи зменшити невизначеність та приймати обґрунтовані рішення.

1.2 Аналіз методів машинного навчання для прогнозування

1.2.1 Теоретичні аспекти методів машинного навчання, які використовуються для прогнозування

Обробка даних для машинного навчання – важливий етап, на якому зосереджено низку ключових завдань для забезпечення якісної та ефективної роботи моделей:

- обробка пропущених значень передбачає виявлення та вирішення пропущених даних, це може включати в себе заповнення пропущених

значень середніми або медіанними значеннями, видалення рядків чи стовпців, які містять пропуски, варто здійснювати цей процес обережно, щоб не втратити необхідну інформацію;

- кодування категоріальних змінних – це перетворення категоріальних даних у числовий формат, який можна використовувати для навчання моделі, це може включати в себе застосування кодування one-hot, яке створює бінарні змінні для кожної категорії;

- нормалізація даних суттєва для того, щоб привести числові значення до одного масштабу, це допомагає уникнути перекосів у вагах моделі, забезпечуючи більш стабільну та точну роботу;

- генерація ознак може включати в себе створення нових характеристик на основі існуючих, щоб розширити потенціал моделі у виявленні складних залежностей в даних.

Усі ці процеси в сукупності допомагають створити добре підготовлені дані, які сприяють ефективній та точній роботі моделей машинного навчання.

Етап розділення даних є значним етапом у підготовці для моделювання в машинному навчанні. Цей процес дозволяє раціонально використовувати наявні дані для навчання та тестування моделей, забезпечуючи оцінку їх ефективності на нових, раніше не використовуваних даних.

Тренувальний набір є підмножиною даних, що використовується для навчання моделі. Модель вивчає структури та закономірності в цих даних, щоб робити прогнози або приймати рішення.

Етап навчання та оцінка моделі є ключовим у процесі машинного навчання. На цьому етапі модель «вчиться» на тренувальних даних і потім оцінюється за її здатністю робити прогнози або класифікувати нові дані.

Під час навчання модель використовує тренувальний набір даних для адаптації і вивчення закономірностей. Це може включати в себе оптимізацію внутрішніх параметрів моделі, таких як ваги у нейронних

мережах чи розгалуження у деревах рішень. Процес тренування триває досягнення оптимальної ефективності на тренувальних даних.

Після завершення тренування модель оцінюється за допомогою тестового набору даних, які раніше не бачила. Оцінка дозволяє визначити, наскільки добре модель узагальнює свої знання на нові дані. Розповсюдження оцінок може включати різні метрики, такі як точність, середньоквадратична помилка, або інші, залежно від типу завдання.

У випадку задач класифікації, модель може бути оцінена за допомогою матриці плутанини, яка відображає кількість правильних та неправильних класифікацій. У випадку регресії, оцінкою може бути графік залежності прогнозованих значень від реальних.

Значущою частиною цього етапу є контроль перенавчання (*overfitting*) та недонавчання (*underfitting*), щоб модель була здатна генералізувати свої знання на нові дані, не стикаючись з проблемами, пов'язаними з перетренуванням або недостатньою адаптацією.

Перенавчання виникає, коли модель надто добре адаптується до тренувальних даних, захоплюючи шум та випадкові відмінності. Це може призвести до того, що модель виявляється неефективною на нових, раніше не бачених даних, оскільки вона вражена шумом, який не має статистичної значущості. Для уникнення перенавчання можна використовувати техніки регуляризації, використовувати більше даних для тренування або вибирати менш складні моделі.

Недонавчання виникає, коли модель недостатньо адаптована до тренувальних даних і, отже, не може ефективно моделювати складні закономірності. Модель може бути недостатньою у виявленні суттєвих залежностей, і це може призвести до низької точності на тренувальних та тестових даних. Для подолання недонавчання можна використовувати більш складні моделі, додавати нові ознаки або збільшувати тренувальний час.

1.2.2 Застосування методів машинного навчання до задач прогнозування часових рядів

Є деякі аспекти структури даних, які суттєві при виборі методу прогнозування часових рядів.

Слід враховувати регулярність та частоту вимірювань у даних. Деякі методи, такі як ARIMA, ефективні для рядів з фіксованим інтервалом вимірювань, тоді як інші, наприклад, методи на основі нейронних мереж, можуть пристосовуватися до різних частот.

Якщо у даних присутні тренди або сезонні варіації, то слід розглядати методи, які можуть враховувати ці особливості. Моделі SARIMA чи нейронні мережі типу LSTM можуть бути ефективними для моделювання таких структур.

Аналіз автокореляції (ACF) та автокореляції зсуву (PACF) може допомогти вибрати підходящий метод. ARIMA-моделі, наприклад, добре впораються з автокорельованими даними, тоді як експоненційне згладжування може бути ефективним для зменшення впливу сезонності.

Розмір набору даних також значимий. Деякі методи можуть бути більш ефективними для великих обсягів даних, тоді як інші можуть давати хороші результати при обмеженому обсязі даних. З великим обсягом даних можна успішно використовувати глибокі нейронні мережі, такі як рекурентні нейронні мережі (RNN) або довготривалі нейронні мережі короткочасної пам'яті (LSTM). Ці моделі дозволяють ефективно враховувати складні взаємозв'язки в часових рядах завдяки їхній здатності автоматичного виявлення шаблонів та трендів. Варто також мати достатньо обчислювальних ресурсів для ефективного тренування та оптимізації цих моделей, особливо в умовах великих обсягів даних.

Якщо дані містять аномалії чи непередбачувані випадки, то моделі здатні до адаптації до цих змін можуть бути більш відповідними.

Наприклад, моделі глибокого навчання можуть допомагати впоратися з складними залежностями в даних.

Швидкість прогнозування грає значну роль при виборі методу для прогнозування часових рядів. Це особливо актуально, якщо потрібно отримувати прогнози в реальному часі або швидко реагувати на зміни в даних.

Прості моделі, такі як експоненційні згладжування або моделі ARIMA, часто мають невелику обчислювальну складність і можуть швидко генерувати прогнози. Вони можуть бути ефективними в ситуаціях, коли суттєву роль відіграє швидкість надає перевагу складнішим, але більш потужним моделям.

З іншого боку, глибокі нейронні мережі, хоча можуть бути потужними у моделюванні складних взаємозв'язків в даних, можуть вимагати значних обчислювальних ресурсів та часу для тренування та прогнозування.

У часових рядах можуть відбуватися різноманітні зміни, такі як сезонність, тренди, аномалії та інші нелінійні варіації. Модель повинна бути гнучкою, щоб враховувати ці зміни та продовжувати надавати точні прогнози.

Одним з ключових аспектів адаптивності є здатність моделі автоматично адаптуватися до нових умов та даних, що надходять. Це означає, що модель може реагувати на зміни у динаміці даних без необхідності ручного або періодичного переналаштування.

Забезпечення адаптивності моделі дозволяє підтримувати її актуальність та ефективність в умовах середовища, що постійно змінюється, та даних, що є одним з ключових аспектів у прогнозуванні часових рядів.

1.3 Актуальність, новизна та можливе застосування

У сучасному світі енергетична безпека стає однією з найважливіших складових національної та міжнародної безпеки. Нестабільність у

політичній сфері, природні катастрофи, терористичні загрози та інші непередбачувані події можуть суттєво підірвати функціонування енергетичних систем та призвести до серйозних проблем у забезпеченні електроенергією населення та інфраструктури.

У таких умовах актуальним стає розвиток методів прогнозування та оптимізації розподілу електроенергії у ситуаціях кризових подій. Це стає особливо значущим у контексті сучасних конфліктів та геополітичних напруг, які можуть мати серйозний вплив на енергетичні системи країн та регіонів.

Дослідження з цієї галузі має на меті розробку та застосування передових методів прогнозування, таких як ARIMA, ARIMAX, SARIMA, SARIMAX, Prophet, DeepAR, для аналізу та управління електропостачанням у ситуаціях кризових подій. Дане дослідження має ключове практичне значення, оскільки його результати можуть бути використані для ефективного управління енергетичними ресурсами та мінімізації наслідків кризових ситуацій у сфері електропостачання.

Дослідження з прогнозування часових рядів для аналізу електропостачання та оптимізації розподілу електроенергії у кризових ситуаціях, які включають блекаути та війну, має велике практичне значення, особливо в контексті сучасних геополітичних конфліктів.

По-перше, в умовах кризи, такої як війна, стає надзвичайно суттєво забезпечити стійке електропостачання для населення, значних інфраструктурних об'єктів та стратегічних установ. Ефективне прогнозування споживання електроенергії дозволяє оперативно реагувати на зміни в попиті та забезпечувати стабільне енергопостачання, навіть у непередбачуваних умовах.

По-друге, під час кризових ситуацій, таких як війна, енергетична інфраструктура може бути піддається атакам та руйнуванням. Застосування методів прогнозування дозволяє оптимізувати розподіл електроенергії до

пошкоджених чи зруйнованих електростанцій, що допомагає відновити електропостачання швидше та ефективніше.

По-третє, під час блекаутів, викликаних війною або іншими кризовими ситуаціями, прогнозування споживання електроенергії допомагає ефективно розподіляти доступні ресурси, забезпечуючи переваги відновлення електропостачання для населення та стратегічних об'єктів.

Таким чином, дослідження, яке ви проводите, має потенціал забезпечити не лише теоретичний внесок у сферу прогнозування часових рядів, але й практичної користі, спрямованої на підвищення ефективності управління енергетичними ресурсами в умовах кризових подій, зокрема війни та блекаутів.

1.4 Постановка задачі

Тож у даній кваліфікаційній роботі ставимо за мету проаналізувати та порівняти методи прогнозування часових рядів для вирішення конкретних завдань у сфері управління електроенергетичними системами.

Згідно з метою у рамках розроблюваної системи поставлено такі задачі:

- детальне вивчення предметної галузі прогнозування часових рядів на прикладі постачання електроенергії;
- вибір методів прогнозування часових рядів для дослідження;
- аналіз існуючих методів аналізу та прогнозування часових рядів, таких як ARIMA, SARIMA, нейронні мережі тощо, з визначенням їх переваг і обмежень;
- проведення експериментального порівняльного аналізу обраних методів з існуючими підходами на реальних даних електромереж з метою оцінки їхньої точності та ефективності.

2 ТЕОРЕТИЧНИЙ ОГЛЯД МЕТОДІВ ПРОГНОЗУВАННЯ ЧАСОВИХ РЯДІВ

2.1 Метод ARIMA

ARIMA – це статистичний метод, який використовується для аналізу та прогнозування часових рядів. Він базується на трьох основних компонентах: авторегресії (AR), інтегруванні (I) та ковзних середніх (MA).

Авторегресія – це концепція, в якій значення часового ряду залежить від попередніх значень того ж ряду в попередні часові моменти. Іншими словами, сьогоднішнє значення залежить від попередніх значень за певний період. Параметр AR (p) визначає порядок авторегресії, тобто кількість попередніх значень, які використовуються для прогнозу.

Інтегрування описує процес, що включається до ARIMA моделі для зняття сезонності та тренду в часовому ряді. Він вимагає різницювання вихідного ряду, тобто віднімання попереднього значення від поточного. Це допомагає зробити ряд стаціонарним, що дозволяє ARIMA моделі краще прогнозувати майбутні значення.

Ковзні середні вказують на зв'язок між поточним значенням часового ряду та помилковим терміном прогнозування, який зазвичай є лінійною комбінацією попередніх значень помилок прогнозування. Параметр MA (q) визначає порядок ковзних середніх, тобто кількість попередніх помилок прогнозування, які використовуються для прогнозу.

ARIMA модель формується як ARIMA (p, d, q), де p , d і q – це порядки авторегресії, інтегрування та ковзних середніх відповідно. Комбінація цих трьох компонентів дозволяє моделі ARIMA прогнозувати майбутні значення часового ряду на основі його минулих значень та виправляти залишкові помилки прогнозування. ARIMA може бути розширеною до моделі SARIMA (сезонна ARIMA), коли враховується сезонність в даних.

Огляд базових концепцій ARIMA є ключовим для розуміння та ефективного використання цього методу прогнозування в аналізі часових рядів.

Перевірка стаціонарності часового ряду є вагомим етапом аналізу перед застосуванням ARIMA моделі. Цей процес може включати кілька підходів.

Візуальний аналіз графіків часового ряду допомагає виявити будь-які видимі тренди, сезонні варіації та інші аномалії. Якщо середнє значення чи дисперсія змінюються від часу, це може свідчити про нестаціонарність.

Для більш точної перевірки стаціонарності, застосовуються статистичні тести, такі як тест Дікі-Фуллера або тест КПСС (Квандт-Перрі Уотсона). Тест Дікі-Фуллера перевіряє наявність стаціонарності, порівнюючи спостережені дані з їх очікуваними значеннями. Це статистичне випробування визначає, чи існує статистично значима залежність від часу.

Додатково, аналіз статистичних характеристик, таких як середнє значення, дисперсія та автокореляційні функції, може допомогти в оцінці стаціонарності ряду. Порівняння цих характеристик в різних періодах може також допомогти виявити будь-які систематичні зміни в часовому ряді.

Загальний висновок про стаціонарність ряду забезпечить засновок для подальшого аналізу та моделювання за допомогою ARIMA.

Диференціювання – це процес, який використовується для зняття тренду або сезонності з часового ряду. Це один із ключових кроків у побудові ARIMA моделі, оскільки ARIMA вимагає стаціонарного часового ряду для правильного прогнозування.

Процес диференціювання полягає в обчисленні різниці між значеннями часового ряду в різних точках часу. Зазвичай використовується перше або друге диференціювання.

Перше диференціювання зводиться до обчислення різниці між кожним наступним значенням ряду та попереднім значенням (2.1).

$$diff_t = X_t - X_{t-1}, \quad (2.1)$$

де $diff_t$ – значення після першого диференціювання в момент часу t ;

X_t – значення часового ряду в момент часу t ;

X_{t-1} – значення часового ряду в попередньому моменті часу.

Друге диференціювання полягає в обчисленні різниці між послідовними значеннями після першого диференціювання (2.2).

$$diff_{t2} = diff_t - diff_{t-1}, \quad (2.2)$$

де $diff_{t2}$ – значення після другого диференціювання в момент часу t ;

$diff_t$ – значення функції у певний момент часу t ;

$diff_{t-1}$ – значення тієї ж функції у попередній момент часу, тобто $t - 1$.

Мета диференціювання полягає в тому, щоб усунути тренд чи сезонні коливання у часовому ряді, зробивши його стаціонарним. Стаціонарний ряд має постійні статистичні характеристики, такі як середнє значення та дисперсія, що сприяє правильному моделюванню ARIMA.

Побудова та оцінка моделі ARIMA – це процес, що включає кілька етапів, спрямованих на вибір оптимальних параметрів моделі та оцінку її адекватності.

Перед початком будь-якої аналізу необхідно визначити початкові значення параметрів моделі ARIMA (p, d, q). Параметр p визначає порядок авторегресії, d – порядок диференціювання, а q – порядок ковзних середніх. Часто використовуються статистичні методи або евристики для попереднього визначення цих параметрів.

Використовуючи аналізи автокореляційної функції (ACF) та часткової автокореляційної функції (PACF), визначається оптимальна комбінація значень параметрів (p, d, q). ACF та PACF допомагають ідентифікувати авторегресійні та ковзні середні компоненти моделі.

Після ідентифікації моделі проводиться оцінка параметрів. Це може включати застосування методів, таких як метод максимальної правдоподібності або метод найменших квадратів, для оцінювання параметрів моделі.

Далі оцінки параметрів моделі ARIMA конструюється фінальна модель. Ця модель зазвичай представляє собою ARIMA (p, d, q) модель, де значення p, d, q визначені на попередньому етапі.

Наступний крок це діагностика для перевірки адекватності моделі. Це включає аналіз залишкових (помилкових) даних для перевірки, чи є вони нормально розподілені та випадковими. Інші тести можуть включати тести на автокореляцію залишків, які повинні бути статистично несуттєвими.

Наступне це прогнозування майбутніх значень часового ряду. Прогнози можуть бути зроблені на кілька кроків уперед, використовуючи оновлені дані.

Побудова та оцінка моделі ARIMA є ітеративним процесом, де параметри моделі налаштовуються та перевіряються для досягнення оптимального прогнозу часового ряду. Необхідно враховувати, що результати моделювання можуть залежати від вибору початкових параметрів, які використовуються під час побудови моделі. Ці кроки допомагають побудувати і аналізувати ARIMA модель для прогнозування часових рядів.

Метод ARIMA має кілька обмежень, які необхідно враховувати під час його використання. По-перше, ARIMA передбачає лінійність відносин між змінними, що може бути обмеженням при моделюванні складних не лінійних взаємозв'язків у часових рядах. По-друге, вибір оптимальних параметрів ARIMA (p, d, q) може бути нетривіальним завданням, і неправильний вибір може призвести до неправильних прогнозів. Це особливо необхідно в ситуаціях, де часовий ряд має складні динамічні властивості.

Поняття стаціонарності також є ключовим для ARIMA, і якщо часовий ряд не є стаціонарним, ARIMA може давати неправильні або надто оптимістичні прогнози. Крім того, ARIMA може мати деякі обмеження у врахуванні сезонності в часовому ряді, хоча це може бути вирішено за допомогою моделей SARIMA.

Невизначеність і чутливість ARIMA до параметрів також є проблемою. Вибір оптимальних значень для параметрів p , d , і q може бути піддається суб'єктивному вирішенню, особливо в ситуаціях, коли даних обмаль, щоб проводити аналіз адекватно.

Незважаючи на ці обмеження, ARIMA має свої переваги, зокрема простоту в реалізації, здатність до моделювання та прогнозування часових рядів з високою точністю у багатьох випадках, а також можливість використання для короткострокового та середньострокового прогнозування в різних галузях, таких як фінанси, економіка, маркетинг тощо.

ARIMA широко використовується в різних галузях для прогнозування часових рядів.

Ці приклади демонструють широкий спектр застосування ARIMA в різних галузях та його значення для прогнозування та прийняття стратегічних рішень.

3.2 Метод ARIMAX

ARIMAX – це розширена версія моделі ARIMA, яка дозволяє включати екзогенні змінні, що дозволяє краще моделювати складні взаємозв'язки між рядами даних.

Класична модель ARIMA є потужним інструментом для аналізу та прогнозування часових рядів. Вона базується на трьох основних складових: авторегресії (AR), інтегрованому руху (I) та ковзному середньому (MA). Однак, ARIMA модель не враховує можливі впливи екзогенних змінних, що

може бути недоліком у випадках, коли існують зовнішні фактори, які впливають на аналізований часовий ряд.

У ARIMAX моделі, додатково до ARIMA компонентів, ми можемо включати екзогенні змінні, які можуть пояснити або доповнити динаміку змін у часовому ряді. Це може бути корисно в різних областях, таких як фінанси, економіка, маркетинг, а також в більш загальних наукових дослідженнях.

$$Y_t = c + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \theta_1 \epsilon_{t-1} + \dots + \theta_q \epsilon_{t-q} + \beta_1 X_{t1} + \dots + \beta_k X_{tk} + \epsilon_t, \quad (2.3)$$

де Y_t – значення часового ряду на часі t ;

c – константа або зміщення;

ϕ_1, \dots, ϕ_p – параметри авторегресії (AR);

$\theta_1, \dots, \theta_q$ – значення часового ряду в попередньому моменті часу;

ϵ_t – біле шумове доданок з нульовим середнім та одиничною дисперсією ($N(0,1)$);

X_{t1}, \dots, X_{tk} – екзогенні змінні;

β_1, \dots, β_k – параметри, що відповідають екзогенним змінним;

p – порядок авторегресії (AR);

q – порядок ковзного середнього (MA).

ARIMAX дозволяє моделювати не тільки внутрішні взаємозв'язки в часовому ряді, але й залежності від зовнішніх факторів. Це робить його корисним інструментом для прогнозування та аналізу в ситуаціях, де суттєво враховувати зовнішні впливи.

Розуміння ARIMAX дозволяє досліджувати складні взаємозв'язки між різними змінними та забезпечує можливість точнішого прогнозування. Таким чином, вивчення ARIMAX є необхідним кроком для тих, хто займається аналізом часових рядів та моделюванням динаміки даних.

Оцінка ARIMAX моделі – це ключовим етап у процесі її розробки та застосування. Під час оцінки ARIMAX моделі проводяться різні аналітичні процедури з метою визначення параметрів моделі та їхнього відповідності до вихідних даних.

Цей процес включає в себе використання методів, таких як метод найменших квадратів або метод максимальної правдоподібності, для оцінки параметрів моделі. Зазвичай використовується програмне забезпечення, таке як Python з бібліотеками для аналізу даних, щоб автоматизувати процес оцінки та отримання параметрів моделі.

Під час оцінки ARIMAX моделі також варто враховувати діагностику моделі, яка включає в себе перевірку на відповідність припущенням ARIMAX моделі. Діагностичні тести можуть включати перевірку на нормальність розподілу залишків, наявність автокореляції в залишках, а також перевірку стаціонарності залишків.

У разі виявлення відхилень від деяких припущень ARIMAX моделі, може знадобитися коригування моделі або вибір альтернативних специфікацій моделі.

Загалом, оцінка ARIMAX моделі вимагає систематичного підходу та використання відповідних статистичних методів для забезпечення точності та надійності результатів аналізу даних.

Ідентифікація та діагностика моделі ARIMAX відіграють ключову роль у визначенні її ефективності та адекватності для аналізу даних.

Ідентифікація моделі полягає в визначенні структури, яка найкраще підходить для моделювання динаміки даних, включаючи вибір відповідних компонентів, таких як авторегресія, інтегрований рух, ковзне середнє та екзогенні змінні.

Після створення моделі варто перевірити її на діагностичні показники, щоб визначити, наскільки добре вона відповідає даним. Діагностика включає аналіз залишків моделі, виявлення їхньої нормальності, відсутності автокореляції та гомоскедастичності.

Також необхідно провести аналіз стаціонарності та гетероскедастичності, оскільки ці аспекти можуть вказувати на недоліки моделі. Використовуючи ці методи, дослідники можуть підтвердити або скоригувати модель, щоб забезпечити її найкращу придатність для аналізу та прогнозування даних.

Прогнозування з ARIMAX моделлю – це процес передбачення майбутніх значень часового ряду з урахуванням екзогенних факторів. ARIMAX модель дозволяє враховувати вплив зовнішніх змінних, що робить її ефективною для прогнозування в умовах, коли на часовий ряд впливають зовнішні фактори.

Процес прогнозування розпочинається зі збору та підготовки вихідних даних, включаючи часовий ряд та екзогенні змінні. Потім будується ARIMAX модель, в якій враховується структура часового ряду, автокореляція, інтегрований рух, ковзні середні, а також вплив екзогенних змінних.

Після побудови моделі проводиться оцінка її точності та адекватності. Це включає в себе ретельну діагностику, перевірку на нормальність розподілу залишків, відсутність автокореляції та інші тести.

Завершальним етапом є прогнозування майбутніх значень часового ряду на основі побудованої ARIMAX моделі. Ці прогнози можуть бути використані для прийняття рішень у різних галузях, таких як економіка, фінанси, маркетинг та інші, де важливо передбачити майбутні тенденції.

ARIMAX модель широко застосовується в різних галузях і науках для аналізу часових рядів та прогнозування майбутніх значень з урахуванням екзогенних факторів.

Використання ARIMAX моделі в різних галузях дає змогу аналізувати складні взаємозв'язки між різними змінними та забезпечує можливість точного прогнозування майбутніх подій.

3.3 Метод SARIMA

SARIMA, або Seasonal Autoregressive Integrated Moving Average, є розширенням моделі ARIMA для аналізу та прогнозування часових рядів з урахуванням сезонної компоненти. Ця модель враховує не лише автокореляцію, тренд та стаціонарність в даних, але й сезонні коливання, що виникають в різні періоди часу.

Основною ідеєю SARIMA є включення сезонної компоненти, яка описує повторювані зміни в часовому ряді протягом певного періоду часу, наприклад, щоденні, щотижневі або щомісячні сезонні варіації.

Модель SARIMA має кілька параметрів, що визначають авторегресійну, інтегровану та ковзну середню структури, а також сезонність. Ці параметри визначаються шляхом аналізу автокореляційних та часткових автокореляційних функцій для забезпечення оптимального підбору.

Побудована SARIMA модель дозволяє аналізувати попередні дані, виявляти патерни та тенденції, а також прогнозувати майбутні значення часового ряду з урахуванням сезонних факторів.

Застосування SARIMA моделі поширене у різних галузях, таких як фінанси, економіка, маркетинг, планування ресурсів підприємства та інші, де слід прогнозувати та аналізувати часові дані з урахуванням сезонності.

Побудова SARIMA моделі є процесом, що включає кілька кроків для визначення оптимальної структури моделі та її параметрів. Починається вона з аналізу часового ряду, щоб зрозуміти його характеристики та особливості.

Спочатку проводиться визначення потрібного ступеня інтегрованості (d) шляхом перевірки на стаціонарність часового ряду. Далі аналізується автокореляційна функція (ACF) та часткова автокореляційна функція (PACF), щоб вибрати початкові значення для параметрів p та q.

Потім визначається сезонність ряду, що може бути виявлено через сезонну ACF та PACF. Після цього обираються параметри P, D, та Q, які відповідають за сезонні компоненти моделі.

$$Y_t = c + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \dots + \theta_q \epsilon_{t-q} + \epsilon_t - \sum_{j=1} \Phi_j Y_{t-s} + \sum_{j=1} \Theta_j \epsilon_{t-s} + \beta_1 X_{t1} + \beta_2 X_{t2} + \dots + \beta_k X_{tk} \quad (2.4)$$

де Y_t – значення часового ряду на часі t ;

c – константа або зміщення;

$\phi_1, \phi_2, \dots, \phi_p$ – параметри авторегресії (AR);

$\theta_1, \theta_2, \dots, \theta_q$ – параметри ковзного середнього (MA);

ϵ_t – біле шумове доданок з нульовим середнім та одиничною дисперсією ($N(0, 1)$);

$X_{t1}, X_{t2}, \dots, X_{tk}$ – екзогенні змінні;

$\beta_1, \beta_2, \dots, \beta_k$ – параметри авторегресії (AR);

p – порядок авторегресії (AR);

q – порядок ковзного середнього (MA);

s – період сезонності;

$\Phi_1, \Phi_2, \dots, \Phi_s$ – параметри сезонної авторегресії;

$\Theta_1, \Theta_2, \dots, \Theta_s$ – параметри сезонного ковзного середнього.

Знаючи всі необхідні параметри, SARIMA модель може бути побудована. Це включає у себе підбір оптимальних значень параметрів та оцінку моделі за допомогою методів максимальної правдоподібності або методу найменших квадратів.

Далі модель піддається діагностиці, щоб перевірити її адекватність та відповідність. Це включає аналіз залишків моделі на нормальність розподілу, відсутність автокореляції та інші діагностичні тести.

У разі потреби параметри моделі можуть бути скориговані та модель переоцінена. Побудована SARIMA модель може бути використана для

аналізу даних та прогнозування майбутніх значень часового ряду з урахуванням сезонних та трендових змін.

Оцінка та діагностика SARIMA моделі є суттєвими етапами в процесі аналізу часових рядів та прогнозування майбутніх значень.

Далі першим кроком є оцінка її параметрів за допомогою методів максимальної правдоподібності або методу найменших квадратів. Це включає знаходження оптимальних значень авторегресійних (p, P), рівнів інтеграції (d, D), ковзних середніх (q, Q) та сезонних періодів.

Після оцінки параметрів моделі необхідно провести діагностику для перевірки адекватності та відповідності моделі даним. Діагностика включає ряд статистичних тестів та аналіз залишків моделі.

Одним з ключових аспектів діагностики є аналіз залишків моделі на нормальність розподілу. Залишки повинні мати нормальний розподіл з нульовим середнім та сталою дисперсією для коректної роботи моделі.

Далі необхідно перевірити відсутність автокореляції в залишках моделі. Для цього використовуються тестування на автокореляцію, такі як тест Льюнга-Бокса.

Діагностика також включає аналіз інших статистичних характеристик залишків, таких як ковзні середні та автокореляційні функції, щоб виявити можливі систематичні відхилення в моделі.

У разі виявлення неприпустимих або неадекватних відхилень, модель може бути скоригована шляхом зміни параметрів або структури. Після проведення діагностики та необхідних корекцій SARIMA модель готова до використання для аналізу та прогнозування майбутніх значень часового ряду.

Прогнозування з використанням SARIMA моделі є необхідним етапом в аналізі часових рядів та прогнозуванні майбутніх значень з урахуванням сезонності.

Як наступний крок можна перейти до прогнозування майбутніх значень часового ряду.

Процес прогнозування полягає у використанні побудованої SARIMA моделі для прогнозування майбутніх значень часового ряду на основі наявних даних. Для цього модель використовується для генерації прогнозів, які враховують авторегресійні, ковзні середні та сезонні компоненти ряду.

Прогнози можуть бути зроблені для будь-якого періоду часу, на який ви хочете прогнозувати значення ряду. Чим більші відомості про сезонні та трендові зміни у часовому ряді, тим більш точні прогнози можуть бути отримані.

Після отримання прогнозів варто оцінити їхню точність та надійність. Це можна зробити шляхом порівняння прогнозованих значень з реальними даними, а також за допомогою різних статистичних метрик, таких як середньоквадратична помилка (RMSE) або середня абсолютна помилка (MAE).

Прогнозування з SARIMA моделлю дозволяє отримувати цінні прогностичні результати, які можуть бути використані для прийняття рішень у бізнесі, економіці, фінансах та інших галузях.

SARIMA модель широко застосовується у багатьох галузях для аналізу та прогнозування часових рядів з урахуванням сезонності.

Поза цими галузями, SARIMA може бути застосований у різних індустріальних, технічних та природних науках для аналізу та прогнозування різноманітних параметрів та явищ з урахуванням сезонності та циклічних змін.

2.4 Метод SARIMAX

Метод SARIMAX (Seasonal Autoregressive Integrated Moving Average with eXogenous factors) є розширенням базового методу SARIMA, що дозволяє моделювати та прогнозувати часові ряди з урахуванням як ендогенних (внутрішніх) змінних, так і екзогенних (зовнішніх) факторів.

Основна ідея методу SARIMAX полягає в тому, щоб враховувати вплив зовнішніх змінних, наприклад, економічні показники, погодні умови тощо, які можуть впливати на часовий ряд, разом з внутрішніми динамічними взаємозв'язками, що вже моделюються SARIMA.

Метод SARIMAX дозволяє розширити базовий SARIMA шляхом включення екзогенних змінних у модель, що дозволяє більш точно моделювати та прогнозувати часовий ряд в умовах, коли на його зміну впливають зовнішні фактори.

Під час використання методу SARIMAX необхідно правильно специфікувати параметри моделі, такі як ступені авторегресії (AR), ковзне середнє (MA), сезонність (S), інтеграції (I) та інші. Параметри моделі визначаються на основі аналізу самого часового ряду та можливих екзогенних змінних (2.5).

$$Y_t = c + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \dots + \theta_q \epsilon_{t-q} + \epsilon_t - \sum_{j=1}^s \Phi_j Y_{t-s} + \sum_{j=1}^s \Theta_j \epsilon_{t-s} + \beta_1 X_{t1} + \beta_2 X_{t2} + \dots + \beta_k X_{tk} \quad (2.5)$$

де Y_t – значення часового ряду на часі t ;

c – константа або зміщення;

$\phi_1, \phi_2, \dots, \phi_p$ – параметри авторегресії (AR);

$\theta_1, \theta_2, \dots, \theta_q$ – параметри ковзного середнього (MA);

ϵ_t – біле шумове доданок з нульовим середнім та одиничною дисперсією ($N(0, 1)$);

$X_{t1}, X_{t2}, \dots, X_{tk}$ – екзогенні змінні;

$\beta_1, \beta_2, \dots, \beta_k$ – параметри авторегресії (AR);

p – порядок авторегресії (AR);

q – порядок ковзного середнього (MA);

s – період сезонності;

$\Phi_1, \Phi_2, \dots, \Phi_s$ – параметри сезонної авторегресії;

$\Theta_1, \Theta_2, \dots, \Theta_s$ – параметри сезонного ковзного середнього.

Після визначення параметрів моделі SARIMAX, модель може бути побудована з використанням спеціалізованих програмних інструментів або бібліотек, таких як Python з бібліотекою statsmodels або R з пакетом forecast.

Після побудови моделі SARIMAX необхідно провести оцінку адекватності моделі. Це може включати оцінку залишкових діагностичних статистик, таких як тест Л'юнга-Бокса на автокореляцію залишків, тест Шапіро-Уїлка на нормальність залишків, та інші.

Крім того, можна порівняти прогнозовані значення моделі з фактичними значеннями часового ряду для перевірки точності прогнозів.

У разі неадекватності моделі SARIMAX може бути необхідно внести корективи, такі як зміна параметрів моделі або включення додаткових екзогенних змінних.

Загалом, побудова та оцінка моделі SARIMAX є ітеративним процесом, який вимагає ретельного аналізу часового ряду та вибору параметрів моделі з метою досягнення найкращої адекватності прогнозів.

Після побудови моделі SARIMAX можна проводити прогнозування майбутніх значень часового ряду, враховуючи як внутрішні динамічні взаємозв'язки, так і вплив зовнішніх факторів. Метод SARIMAX є корисним інструментом для прогнозування різних типів часових рядів, таких як фінансові дані, виробничі випуски, популяційні тенденції тощо.

Прогнозування з використанням моделі SARIMAX є значним етапом в аналізі часових рядів.

Коли модель SARIMAX побудована і оцінена, можна використовувати її для прогнозування майбутніх значень часового ряду. Прогнози SARIMAX базуються на внутрішніх динамічних взаємозв'язках, які моделюються за допомогою ARIMA компонентів, а також на зовнішніх факторах, що враховуються у вигляді екзогенних змінних.

Для прогнозування майбутніх значень часового ряду, спочатку необхідно визначити період, на який потрібно здійснити прогноз. Потім

можна використати побудовану модель SARIMAX, щоб отримати прогнозовані значення на цей період.

Під час прогнозування з використанням SARIMAX слід враховувати, що прогнози можуть бути супроводжені деякою неозначеністю. Точність прогнозів може залежати від якості моделі, кількості доступних даних, а також від стабільності умов, на яких базується модель.

Для оцінки точності прогнозів SARIMAX можна використовувати різні метрики, такі як середньоквадратична помилка (MSE), середня абсолютна помилка (MAE) або коефіцієнт детермінації (R-squared).

Прогнози SARIMAX можуть бути корисними для прийняття рішень у різних областях, таких як фінанси, економіка, маркетинг, та інші, де суттєво передбачати майбутні тенденції на основі історичних даних.

Загалом, прогнозування з використанням моделі SARIMAX дозволяє отримати оцінку майбутніх значень часового ряду, що може бути корисним для планування та управління в різних галузях та сферах діяльності.

Метод SARIMAX може використовуватись у різних областях. Як приклад, прогнозування продажів у роздрібній торгівлі. Магазины можуть використовувати модель SARIMAX для прогнозування продажів на основі історичних даних продажів, рекламних витрат, святкових періодів тощо. Це допомагає їм планувати запаси, розподіляти ресурси та оптимізувати стратегії продажу.

Ці приклади ілюструють різноманітність застосування методу SARIMAX у різних сферах та його значення для прогнозування та планування.

3.5 Метод DeepAR

DeepAR – це модель для прогнозування часових рядів, яка базується на глибокому навчанні. Розроблена командою Amazon і доступна на платформі AWS SageMaker. Основна ідея DeepAR полягає в тому, щоб

навчити модель розуміти шаблони та закономірності в часових рядах та використовувати ці знання для прогнозування майбутніх значень.

Архітектура DeepAR використовує рекурентні нейронні мережі (RNN), зокрема LSTM (Long Short-Term Memory) або GRU (Gated Recurrent Unit), для аналізу динаміки часових рядів. Ці типи нейронних мереж особливо ефективні для роботи з послідовностями, оскільки вони можуть запам'ятовувати попередні стани та враховувати їх при обробці нових вхідних даних (2.5).

$$Y_{t+1} = f(Y_t, Y_{t-1}, \dots, Y_{t-\delta+1}, X_{t+1}, X_t, \dots, X_{t-\delta+1}) \quad (2.5)$$

де Y_{t+1} – значення, яке ми намагаємося передбачити;

$Y_t, Y_{t-1}, \dots, Y_{t-\delta+1}$ – попередні значення часового ряду на певних часових кроках;

$Y_{t+1}, Y_t, \dots, Y_{t-\delta+1}$ – екзогенні змінні, які можуть бути включені у модель;

f – функція, яка представляє собою архітектуру нейронної мережі, наприклад, рекурентну нейронну мережу (RNN), довготривалу короткочасну пам'ять (LSTM) або згорткову нейронну мережу (CNN).

DeepAR також враховує контекстні фактори, які можуть впливати на часовий ряд. Наприклад, якщо прогнозується продажі продуктів, модель може враховувати сезонність, рекламні кампанії або святкові дні.

Один з ключових аспектів DeepAR – це здатність автоматично враховувати інформацію про часовий ряд, таку як тренди, сезонність та інші закономірності. Модель може використовувати цю інформацію для генерації прогнозів з різною довжиною горизонту.

Однією з суттєвих переваг DeepAR є його здатність до управління низькими рівнями даних та малою кількістю прикладів. Це особливо корисно для сценаріїв, де доступні обмежені обсяги даних для навчання моделі.

Загалом, DeepAR є потужним інструментом для прогнозування часових рядів, що забезпечує зручний і ефективний спосіб для розробки та впровадження моделей прогнозування на платформі AWS SageMaker.

Інтеграція DeepAR з платформою AWS SageMaker дозволяє використовувати потужність глибокого навчання для прогнозування часових рядів у зручному та ефективному середовищі. AWS SageMaker надає інструменти для розробки, навчання та розгортання моделей машинного навчання, включаючи DeepAR.

Користувачі можуть використовувати DeepAR на SageMaker для прогнозування часових рядів, використовуючи потужність глибокого навчання.

Інтеграція забезпечує деякі переваги. По-перше, простота використання: DeepAR доступний як один з алгоритмів в AWS SageMaker, що робить процес розробки та навчання моделей зручним і простим.

По-друге, ефективне навчання: AWS SageMaker надає розширені можливості для навчання моделей DeepAR, забезпечуючи автоматизоване керування ресурсами та інфраструктурою.

Наступне – налаштування гіперпараметрів: користувачі мають можливість налаштувати гіперпараметри DeepAR згідно зі своїми потребами та характеристиками даних.

Ще однією перевагою є оцінка та налагодження моделі: після навчання моделі користувачі можуть оцінити її результати та внести налаштування для поліпшення якості прогнозів.

Розгортання на продуктове середовище – це ще одна перевага. Після успішного навчання модель можна розгорнути на продуктовому середовищі, щоб використовувати її для генерації прогнозів у реальному часі.

Загалом, інтеграція DeepAR з AWS SageMaker дозволяє розробникам та дослідникам легко і ефективно використовувати глибоке навчання для

прогнозування часових рядів, спрощуючи процес розробки та впровадження моделей.

Налаштування та навчання моделі DeerAR включає кілька етапів, які спрямовані на підготовку даних, вибір гіперпараметрів та сам процес навчання.

Початково необхідно підготувати дані для моделі DeerAR. Це включає очищення та попередню обробку даних, розділення їх на тренувальний, валідаційний та тестовий набори, а також перетворення їх у формат, придатний для DeerAR.

Наступний крок – вибираються гіперпараметри моделі. Гіперпараметри включають параметри архітектури мережі (наприклад, кількість шарів та нейронів), параметри оптимізації (наприклад, швидкість навчання) та параметри регуляризації. Вибір гіперпараметрів зазвичай відбувається на основі експериментів з валідаційним набором даних.

Далі можна перейти до процесу навчання моделі. Під час навчання DeerAR використовує дані тренувального набору для побудови моделі, яка може передбачати майбутні значення часових рядів. Слід використовувати оптимізатори, які дозволяють збільшити швидкість навчання та знизити ризик перенавчання моделі.

Після завершення процесу навчання модель може бути оцінена за допомогою тестового набору даних. Це дозволяє оцінити якість прогнозів моделі та зрозуміти, наскільки добре вона справляється з прогнозуванням майбутніх значень часових рядів.

Узагальнюючи, налаштування та навчання моделі DeerAR – це ітеративний процес, який включає в себе підготовку даних, вибір гіперпараметрів та навчання моделі з метою отримання якісних прогнозів часових рядів.

Коли закінчили вивчення моделі DeerAR, варто провести оцінку результатів. Це включає аналіз точності прогнозів моделі на тестовому наборі даних. Метрики, такі як середня квадратична помилка, середня

абсолютна помилка, коефіцієнт кореляції тощо, використовуються для оцінки точності моделі.

Подальший крок – це необхідно підготувати її до розгортання. Це включає пакування моделі відповідним чином для подальшого використання. У разі DeepAR це може означати експорт навченої моделі у відповідний формат.

Після підготовки модель може бути розгорнута на продуктовому середовищі. Це може бути виконано через AWS SageMaker або будь-який інший сервіс, який підтримує розгортання моделей машинного навчання. Під час розгортання необхідно врахувати фактори, такі як масштабність, безпека та ефективність.

Коли модель розгорнута, вона може бути використана для генерації прогнозів у реальному часі або у реальних виробничих сценаріях. Необхідно слідкувати за результатами моделі після розгортання та вчасно вносити зміни або оновлення для покращення її продуктивності та точності.

2.6 Метод Prophet

Модель Prophet – це процедура автоматичного прогнозування часових рядів, яка була розроблена Facebook для рішення різних завдань у сфері аналізу даних та прогнозування. Вона надає зручний і потужний інструмент для прогнозування часових рядів, особливо тих, що мають складну сезонність і тенденції. Модель Prophet була створена з урахуванням потреб бізнес-користувачів та дослідників, які часто мають справу зі складними часовими рядами, і вона дозволяє їм ефективно прогнозувати майбутні значення, звертаючи увагу на різні впливи, такі як щоденні та щотижневі сезонні зміни, свята та події. Однією з ключових особливостей моделі є її здатність робити прогнози з використанням лише історичних даних, без необхідності вручну встановлювати складні моделі або вибирати параметри.

Модель Prophet використовує адитивну модель, що включає в себе три основні компоненти: тренд, сезонність та святкові ефекти. Тренд – це гладка зміна в часовому ряді, яку модель може автоматично виявити та включити у прогноз. Сезонність описує періодичні зміни, такі як щоденні, щотижневі або щорічні патерни, що можуть бути притаманні деяким даним. Святкові ефекти дозволяють моделі враховувати вплив свят, подій або інших важливих дат на часовий ряд (2.6).

$$y(t) = g(t) + s(t) + h(t) + \epsilon_t \quad (2.6)$$

де $y(t)$ – значення часового ряду у момент часу t ;

$g(t)$ – тренд, який моделює зміну середнього значення часового ряду з часом;

$s(t)$ – сезонність, яка представляє собою повторювані циклічні зміни у часовому ряді (наприклад, щоденні, щотижневі, щомісячні сезонні ефекти);

$h(t)$ – святкові ефекти або інші випадкові зміни;

ϵ_t – шумовий член, який відображає випадкову складову часового ряду.

Однією з особливостей моделі Prophet є її здатність обробляти пропущені дані та аномалії в часових рядах, що робить її досить гнучкою для роботи з реальними даними, які часто можуть бути неповними або містити нетипові значення.

Узагальнюючи, модель Prophet надає зручний і потужний інструмент для прогнозування часових рядів, дозволяючи користувачам ефективно моделювати та прогнозувати майбутні значення, звертаючи увагу на різні фактори, що впливають на часовий ряд.

Метод Prophet широко використовується в різних областях для прогнозування часових рядів і вирішення реальних завдань.

Враховуючи ці різноманітні застосування, метод Prophet є потужним інструментом для аналізу та прогнозування часових рядів у різних сферах діяльності.

3 ПРАКТИЧНЕ ДОСЛІДЖЕННЯ МЕТОДІВ ПРОГНОЗУВАННЯ ЧАСОВИХ РЯДІВ

3.1 Дані та підготовка до дослідження

Проблема енергопостачання є однією з найбільш суттєвих та актуальних у сучасному світі, а особливо для України у часи війни сьогодні. Світове населення швидко зростає, і разом з ним зростає і потреба в електроенергії. Проте, багато країн та регіонів стикаються з різними викликами, пов'язаними з енергопостачанням.

Перш за все, необхідно забезпечити постачання електроенергії в межах поточного попиту. Недостатнє або нестабільне енергопостачання може призвести до серйозних економічних та соціальних проблем.

Збільшення енергоефективності є необхідним аспектом для зменшення споживання та викидів вуглецю. Прогнозування споживання електроенергії є ключовим етапом у розробці стратегій оптимізації та планування енергосистем.

З ростом свідомості про зміни клімату та потребу у зменшенні викидів парникових газів, використання відновлюваних джерел енергії, таких як сонячна та вітрова енергія, стає все більш поширеним. Прогнозування споживання електроенергії може допомогти у кращому управлінні цими джерелами та інтеграції їх у енергосистему.

Енергопостачання має бути не лише ефективним, але й надійним. Прогнозування споживання електроенергії допомагає у виявленні патернів та встановленні резервних планів для забезпечення безперебійного постачання.

У часи війни в Україні розподіл енергопостачання вкрай необхідний, щоб утримувати показники економіки та мати змогу ефективно розподіляти енергію між споживачами під час блекаутів, ремонтувати електростанції тощо.

У цьому контексті дослідження часових рядів споживання електроенергії має велике значення. Прогнозування споживання на майбутні періоди дозволяє енергетичним компаніям та урядовим органам ефективно планувати та управляти виробництвом та розподілом електроенергії. Це також дозволяє споживачам, зокрема промисловим підприємствам та домогосподарствам, ефективно управляти своїм споживанням та оптимізувати витрати на електроенергію.

У дослідженні розглянемо різні методи прогнозування часових рядів споживання електроенергії та порівняємо їхню ефективність. Це дозволить краще розуміти та передбачати зміни у споживанні електроенергії, що в свою чергу сприятиме більш ефективному управлінню енергопостачанням та досягненню цілей сталого розвитку.

Результати напряду залежать від даних, за допомогою яких воно проводиться. Розглянемо детальніше особливості датасету, що буде використовуватися у дослідженні.

У цьому дослідженні розглянемо різні методи прогнозування часових рядів споживання електроенергії на основі датасету, що містить дані про споживання електроенергії різними клієнтами. Датасет складається з вимірів споживання кожні 15 хвилин протягом дня у Португалії. Значення вимірів виражені в кіловат-годинах (kW).

Датасет не містить пропущених значень, що робить його чистим та готовим до аналізу. Це дозволяє уникнути додаткових обробок даних та зосередитися безпосередньо на моделюванні та прогнозуванні.

Споживання електроенергії вимірюється кожні 15 хвилин, що дозволяє отримати досить детальні дані для аналізу та прогнозування.

Значення споживання виражені в кіловат-годинах (kW), і для переведення їх у кіловат-години (kWh) потрібно поділити на 4. Це стандартизоване значення, що спрощує обробку та аналіз даних.

Часові мітки відповідають португальському часу. Це варто враховувати при аналізі та прогнозуванні, оскільки можливі різні часові зони та періоди, що можуть вплинути на споживання електроенергії.

Щорічно в березні та жовтні відбуваються зміни часу, що може вплинути на дані. Наприклад, у березні, у день зміни часу, значення між 1:00 ранку та 2:00 ранку дорівнюють нулю для всіх точок. У жовтні, у день зміни часу, значення між 1:00 ранку та 2:00 ранку агрегують споживання двох годин. Ці аномалії потрібно враховувати при обробці даних та аналізі.

Кожен стовпець датасету відповідає споживачеві електроенергії. Деякі клієнти можуть мати різний тип споживання, а отже, можуть потребувати різних моделей прогнозування.

Загальною характеристикою є те, що датасет містить детальні дані щодо споживання електроенергії на різних підприємствах або установках. Це дозволяє здійснювати аналіз та прогнозування споживання для різних сценаріїв та типів клієнтів. Візуалізація перших 5 днів зображена на рисунку 3.1.




Рисунок 3.1 – Візуалізація датасету, перші 5 днів

Кожен стовпець датасету відповідає одному клієнту. Деякі клієнти були створені після 2011 року, і для них споживання електроенергії до цього часу вважається нульовим. Часові мітки відповідають португальському часу. Однак кожного року в березні, у день зміни часу (коли година переходить з 1:00 на 2:00), значення між 1:00 ранку та 2:00 ранку дорівнюють нулю для всіх точок. Також кожного року в жовтні, у день зміни часу (коли година переходить з 2:00 на 1:00), значення між 1:00 ранку та 2:00 ранку агрегують споживання двох годин. Датасет зображено на рисунку 3.2.

DateTime	ts1	ts2	ts3	ts4	ts5	ts6	ts7	ts8	ts9
2012-01-01 00:00:00	12.690355	68.278805	231.972198	412.601626	213.414634	1053.571429	27.133974	838.383838	223.7762
2012-01-01 01:00:00	16.497462	90.327169	309.296264	552.845528	289.024390	1360.119048	27.133974	1101.010101	269.2307
2012-01-01 02:00:00	19.035533	93.883357	309.296264	556.910569	269.512195	1238.095238	27.699265	1023.569024	267.4825
2012-01-01 03:00:00	17.766497	88.904694	309.296264	441.056911	210.975610	842.261905	22.611645	831.649832	176.5734
2012-01-01 04:00:00	19.035533	87.482219	309.296264	343.495935	189.024390	645.833333	14.132278	730.639731	185.3146

Рисунок 3.2 – Скріншот частини датасету

Мета цього дослідження полягає у застосуванні різних методів прогнозування, таких як ARIMA, ARIMAX, SARIMA, SARIMAX, Prophet, ДеерAR, для прогнозування споживання електроенергії на майбутній період. Кожен з цих методів має свої переваги та недоліки, і мета дослідження полягає у визначенні, який з методів найбільш ефективний у даному контексті.

Подальший аналіз та порівняння результатів цих методів прогнозування дозволить зробити висновки про їхню ефективність та застосовність у практичних завданнях прогнозування споживання електроенергії.

Треба більш детально розглянути датасет, щоб далі працювати з ним.

Гарно описує датасет розклад часового ряду на складові: тренд, сезонність та залишкову складову.

Тренд показує загальну тенденцію часового ряду впродовж часу. Вона відображає, як змінюється середнє значення ряду відносно часу.

Сезонність відображає повторювані патерни у даних, які повторюються через фіксований період часу. Наприклад, якщо ряд представляє щоденне споживання електроенергії, то сезонність може показувати пікові часи споживання протягом кожного дня.

Залишкова складова відображає відхилення даних від тренду та сезонності. Вона включає в себе будь-які випадкові або неперіодичні коливання, які не вдається пояснити за допомогою тренду та сезонності.

Графічне відображення цих складових дозволяє краще зрозуміти структуру та патерни часового ряду, що може бути корисним при подальшому аналізі та прогнозуванні. Розклад часового ряду на складові зображено на рисунку 3.3.




Рисунок 3.3 – Розклад часового ряду на складові

Тест Дікі-Фуллера це статистичний тест, що використовується для перевірки наявності стаціонарності в часових рядах. Стаціонарність є

значущою властивістю часових рядів, оскільки багато моделей та методів аналізу передбачають, що дані є стаціонарними.

Стаціонарність часового ряду означає, що його статистичні властивості, такі як середнє значення та дисперсія, залишаються постійними з часом. Це варто враховувати для того, щоб прогнозування були надійними та ефективними. Якщо часовий ряд не є стаціонарним, це може призвести до неправильних прогнозів та некоректного аналізу даних. Результат тесту Дікі-Фуллера зображено на рисунку 3.4.

```

Test Statistic          -1.202749e+01
p-value                 2.925873e-22
#Lags Used              4.900000e+01
Number of Observations Used 2.625500e+04
Critical Value (10%)    -2.566829e+00
Critical Value (1%)     -3.430599e+00
Critical Value (5%)     -2.861650e+00
dtype: float64

```

Рисунок 3.4 – Результат тесту Дікі-Фуллера

Тестова статистика має від'ємне значення, що свідчить про те, що ряд є стаціонарним. Це підтверджується також і низьким значенням p-value, яке дуже близьке до нуля.

Значення p-value дуже низьке, що вказує на відхилення нульової гіпотези про нестаціонарність ряду. Це означає, що наш часовий ряд є стаціонарним.

Кількість використаних затримок та кількість спостережень, що використовуються вказують на те, скільки затримок було використано в тесті та скільки спостережень було взято до уваги для обчислення тестової статистики.

Значення критичних значень також надані, що допомагає оцінити, наскільки тестова статистика знаходиться поруч з критичними значеннями

для різних рівнів значущості. У даному випадку, тестова статистика значно менше критичних значень, що підтверджує стаціонарність ряду.

З огляду на ці результати, можна зробити висновок, що часовий ряд є стаціонарним, що означає відсутність явних трендів або сезонності, які потребують моделювання у ARIMA моделі. Тому додаткове диференціювання часового ряду не буде застосовуватися, а сезонність може бути врахована в інших моделях, таких як SARIMA або ARIMAX.

Графіки ACF (Autocorrelation Function) та PACF (Partial Autocorrelation Function) будуються для аналізу автокореляційних зв'язків у часовому ряді. Це візуалізовано на рисунку 3.5.

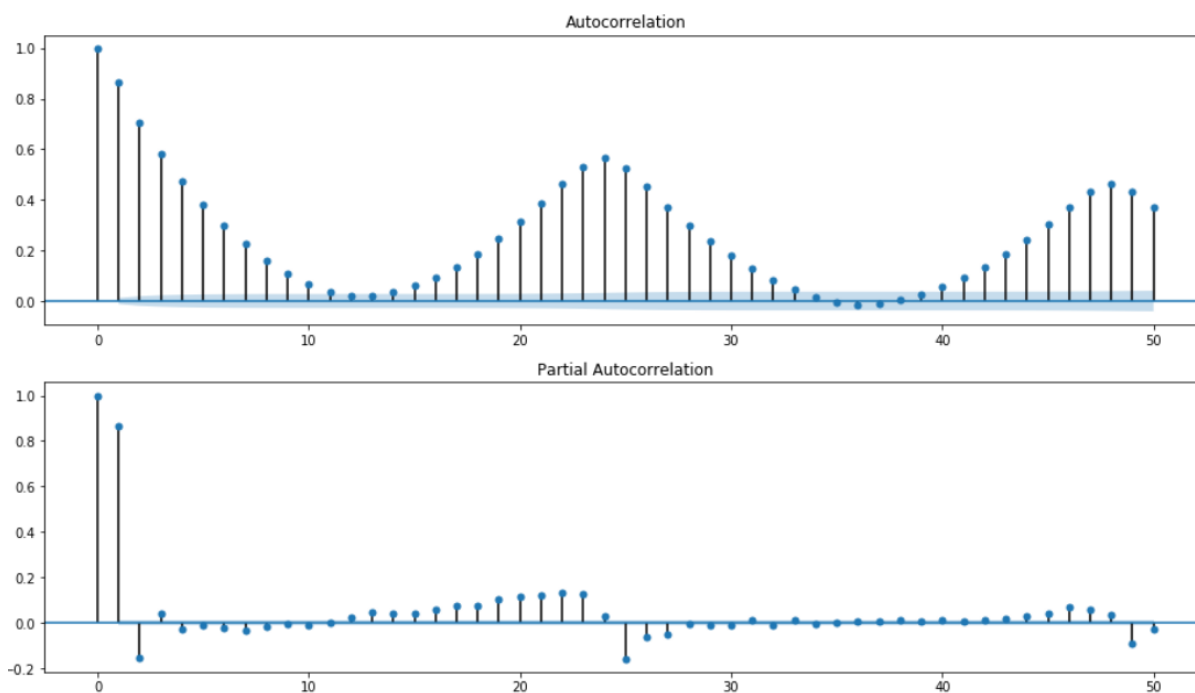


Рисунок 3.5 – Графіки ACF та PACF

Основна мета їх побудови полягає в тому, щоб виявити кореляційні зв'язки між значеннями часового ряду на різних часових затримках.

Графік ACF відображає кореляцію між значеннями часового ряду та його відстроченими (затриманими) копіями для різних затримок. Кожна точка на графіку представляє кореляцію між значеннями ряду на поточному

моменті часу та значеннями ряду на певну кількість попередніх моментів часу. Графік ACF дозволяє визначити патерни сезонності та кореляційні структури у часовому ряді.

Графік PACF відображає часткову кореляцію між значеннями часового ряду та його відстроченими (затриманими) копіями, контролюючи значення часового ряду на всіх коротших затримках.

Іншими словами, PACF відображає кореляцію між значеннями ряду на певній затримці, враховуючи вплив усіх інших затримок.

Графік PACF дозволяє виявити лаги, що мають значущий вплив на поточні значення ряду та ідентифікувати модель для ARIMA.

3.2 ARIMA

Щоб знайти найкращу модель ARIMA для прогнозування часового ряду, треба обрати оптимальні параметри.

Ціль полягає в тому, щоб знайти модель, яка найкраще підходить для прогнозування конкретного часового ряду. Модель ARIMA має три параметри (p , d , q), які визначають структуру моделі. Шляхом вибору оптимальних значень цих параметрів можна досягти більш точного прогнозу часового ряду.

Оптимізація параметрів дозволяє уникнути таких проблем, як перенавчання або недонавчання моделі. Підбір найкращих параметрів допомагає зробити модель більш універсальною і здатною до прогнозування майбутніх значень часового ряду.

Коректно підібрані параметри дозволяють побудувати модель, яка краще враховує внутрішні залежності та структуру часового ряду, що забезпечує надійність прогнозів на майбутнє.

Використання оптимальних параметрів дозволяє побудувати модель, яка максимально ефективно використовує наявні дані і ресурси для прогнозування майбутніх значень.

Отже, оптимізація параметрів моделі ARIMA є важливим етапом у процесі розробки прогностичних моделей для аналізу та прогнозування часових рядів.

У першу чергу дані розділяються на навчальний і тестовий набори. Потім за допомогою циклу виконується перебір різних комбінацій параметрів ARIMA. Для кожної комбінації параметрів модель будується на навчальних даних, а потім здійснюється прогноз на тестовому наборі.

Результати прогнозу оцінюються за допомогою метрики symmetric mean absolute percentage error (sMAPE). Після чого, обирається модель з найкращою прогностичною здатністю. Формула метрики вказана відповідає формулі 3.1.

$$sMAPE = n * 100\% \sum_{t=1}^n (|At| + |Ft|) / 2|Ft - At|, \quad (3.1)$$

де A_t – фактичне значення в часовій точці t ;

F_t – прогнозоване значення в часовій точці t ;

n – кількість точок у тестовому наборі.

Отримані оптимальні параметри використовуються для побудови кінцевої моделі ARIMA, яка тренується на всьому наборі даних (навчальний та тестовий) і використовується для генерації прогнозів на тестовому періоді.

У результаті ми отримуємо найкращу модель ARIMA з оптимальними параметрами для даного часового ряду, а також її характеристики, такі як коефіцієнти моделі та додаткову статистичну інформацію.

За результатами оптимізації, найкращою моделлю ARIMA є та, яка має параметри $(p, d, q) = (3, 0, 2)$.

У наданих результатах бачимо, що побудована модель ARIMA (3, 0, 2) має наступні характеристики: значення коефіцієнтів моделі (const, ar.L1, ar.L2, ar.L3, ma.L1, ma.L2), які характеризують авторегресійні та ковзні

середні ефекти, статистичні показники, такі як стандартне відхилення і довірчі інтервали для кожного коефіцієнта, значення критеріїв AIC, BIC, HQIC, які допомагають порівнювати різні моделі та вибирати найкращу з них.

Точність прогнозування оцінюється за допомогою метрики sMAPE. Чим менше значення sMAPE, тим краще прогнозуюча модель. Часто sMAPE виражають у відсотках, що дає зручну інтерпретацію результатів.

Після аналізу результатів можна прийти до наступних висновків: модель ARIMA (3, 0, 2) є найкращою серед розглянутих моделей з оптимальними параметрами для прогнозування часового ряду, значення sMAPE може бути використане для порівняння точності прогнозів цієї моделі з іншими моделями або базовими підходами, а додатковий аналіз статистичних показників може допомогти зрозуміти структуру та характеристики прогнозуючої моделі.

Загалом, отримані результати надають суттєву інформацію для подальшого застосування моделі ARIMA у прогнозуванні часових рядів. Результати представлені на рисунки 3.6, 3.7, 3.8.

```
Best model: ARIMA(3, 0, 2)
                                ARMA Model Results
=====
Dep. Variable:                   ts10    No. Observations:           672
Model:                           ARMA(3, 2)  Log Likelihood              -3487.586
Method:                           css-mle   S.D. of innovations          43.372
Date:                             Sat, 13 Oct 2018    AIC                          6989.172
Time:                             23:25:10         BIC                           7020.744
Sample:                           12-03-2014       HQIC                          7001.400
                                - 12-31-2014
```

Рисунок 3.6 – Скріншот результатів оптимізації параметрів

```

=====
              coef      std err          z      P>|z|      [0.025      0.975]
-----
const          248.0585      6.760      36.696      0.000      234.809      261.307
ar.L1.ts10      1.2708      0.190      6.699      0.000      0.899      1.643
ar.L2.ts10     -0.0405      0.303     -0.134      0.894     -0.634      0.553
ar.L3.ts10     -0.3086      0.137     -2.247      0.025     -0.578     -0.039
ma.L1.ts10     -0.2202      0.180     -1.223      0.222     -0.573      0.133
ma.L2.ts10     -0.4637      0.120     -3.871      0.000     -0.699     -0.229
=====

```

Рисунок 3.7 – Скріншот результатів оптимізації параметрів

```

              Roots
=====
              Real      Imaginary      Modulus      Frequency
-----
AR.1          1.1366      -0.2363j      1.1609      -0.0326
AR.2          1.1366      +0.2363j      1.1609      0.0326
AR.3         -2.4044      -0.0000j      2.4044      -0.5000
MA.1          1.2501      +0.0000j      1.2501      0.0000
MA.2         -1.7249      +0.0000j      1.7249      0.5000
-----
Wall time: 14.9 s

```

Рисунок 3.8 – Скріншот результатів оптимізації параметрів

Для візуалізації було побудовано графік, на якому відображаються фактичні та прогнозовані значення часового ряду. Основна мета цього коду це візуальна оцінка точності прогнозування моделі ARIMA.

Чорна лінія це фактичні значення часового ряду, які використовуються для тренування та оцінки моделі. Ця лінія показує, як змінювалася величина часового ряду в часі.

Синя лінія це прогнозовані значення, які були згенеровані моделлю ARIMA з використанням оптимальних параметрів, визначених під час оптимізації. Синя лінія відображає те, якими очікується бути значення часового ряду в майбутньому відповідно до прогнозу моделі.

Червона вертикальна лінія це відмітка, що відокремлює тестові дані від тренувальних даних. Все, що знаходиться праворуч від цієї лінії, є

прогнозованими даними, а все ліворуч – використовувалося для тренування моделі.

Графік дозволяє візуально порівняти прогнозовані значення з фактичними даними та оцінити, наскільки точно модель ARIMA відтворює зміни в часовому ряді, графік зображено на рисунку 3.9.




Рисунок 3.9 – Відтворення моделлю ARIMA зміни часовому ряді

Побудова графіка гистограми розподілу значень метрики sMASE для кожного часового ряду є важливою для оцінки ефективності моделі прогнозування.

Розташування пікової точки гистограми може вказувати на середнє значення sMASE для набору даних. Чим більше пік, тим більше часових рядів мають значення sMASE, близьке до цієї середньої величини.

Ширина та форма гистограми вказують на розмах значень sMASE. Якщо гистограма широка і має велику дисперсію, це може означати, що точність моделі значно варіюється серед різних часових рядів.

Форма гистограми також може вказувати на симетричність або асиметрію розподілу sMASE. Якщо гистограма симетрична, це означає, що результати прогнозування майже однаково точні для більшості часових рядів. У той час як асиметрична гистограма може вказувати на те, що деякі часові ряди мають значно кращі або гірші результати, ніж інші.

Висота стовпчиків гистограми відображає кількість часових рядів з певним значенням sMASE. Чим вищий стовпець, тим більше часових рядів мають значення метрики в цьому діапазоні.

Графік зображено на рисунку 3.10.




Рисунок 3.10 – Гістограми розподілу значень метрики sMASE

Загалом, аналізуючи цей графік, можна зрозуміти, як ефективно модель ARIMA прогнозує значення для різних часових рядів, а також виявити будь-які особливості або варіації в точності прогнозів.

Для візуальної оцінки якості прогнозів моделі ARIMA для кількох часових рядів одночасно побудуємо графіки, зображено на рисунку 3.11.

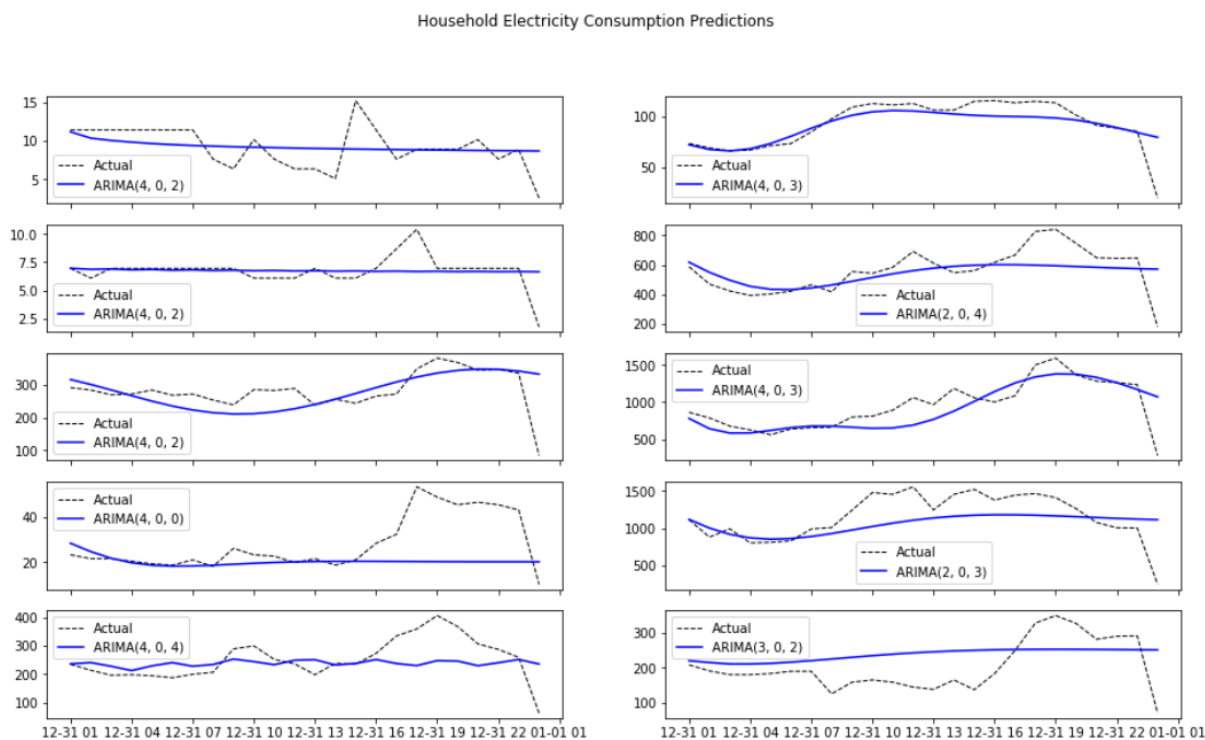


Рисунок 3.11 – Оцінка якості прогнозів моделі ARIMA

Графіки розташовані у вигляді матриці 5x2, де кожен рядок представляє окремий часовий ряд. Кожен графік має два стовпці, що відображають фактичні значення та прогнози для цього часового ряду.

Сині лінії на графіках показують прогнозовані значення, тоді як чорні лінії пунктиром відображають фактичні значення часового ряду. Це дозволяє порівняти прогнози моделі з реальними даними та оцінити їх точність. Якщо прогнози (сині лінії) добре адаптовані до фактичних даних (чорні пунктирні лінії), це може свідчити про високу точність моделі. Навпаки, якщо прогнози відхиляються від фактичних даних, це може свідчити про неадекватність моделі або недостатню адаптацію до вихідних даних.

3.3 ARIMAX

Ті самі дії виконаємо і для наступної моделі – ARIMAX. Для порівняння результатів ARIMAX з результатами для моделі ARIMA

оберемо найкращу модель. У випадку ARIMAX найкращою моделлю виявилася SARIMAX (3, 0, 2), що відрізняється від ARIMA (3, 0, 2).

Параметри ARIMAX включають коефіцієнти для днів тижня, що вказує на використання екзогенних змінних у моделі, тоді як у ARIMA таких змінних не враховувалося. Це може вказувати на те, що дні тижня мають велике значення для прогнозування енергоспоживання.

Значення AIC та BIC для ARIMAX (AIC = 6993.569, BIC = 7052.202) дещо вищі, ніж для ARIMA, що може вказувати на кращу адаптацію ARIMAX до даних.

Характеристики моделі, такі як Ljung-Box (Q) і Jarque-Bera (JB) тесту, слугують оцінкою адекватності моделі. У даному випадку, значення Ljung-Box (Q) і Jarque-Bera (JB) тестів доволі низькі, що може свідчити про адекватність моделі. Однак, варто звернути увагу на попередження щодо гетероскедастичності.

Час обчислення моделі ARIMAX трохи більший, ніж у випадку ARIMA (1 хвилина 3 секунди проти 14.9 секунд). Це може бути пов'язано з операціями, пов'язаними з використанням екзогенних змінних у моделі.

Результати моделі ARIMAX здаються дещо кращими, оскільки вони враховують екзогенні змінні (дні тижня), що може покращити точність прогнозів, особливо якщо ці змінні відіграють ключову роль у динаміці енергоспоживання. Результати зображені на рисунках 3.12, 3.13, 3.14.

```
Best model: ARIMAX(3, 0, 2)
                    Statespace Model Results
=====
Dep. Variable:      ts10      No. Observations:      672
Model:              SARIMAX(3, 0, 2)  Log Likelihood          -3483.784
Date:               Sat, 06 Oct 2018  AIC                       6993.569
Time:               18:19:43         BIC                       7052.202
Sample:             12-03-2014       HQIC                      7016.276
                   - 12-31-2014
Covariance Type:    opg
```

Рисунок 3.12 – Оцінка якості прогнозів моделі ARIMAX

```

=====
              coef      std err          z      P>|z|      [0.025      0.975]
-----
mon             246.7806      11.813      20.891      0.000      223.628      269.933
tue             273.6692      11.812      23.169      0.000      250.518      296.820
wed             258.1991      15.955      16.183      0.000      226.929      289.469
thu             261.3988      14.936      17.501      0.000      232.125      290.673
fri             246.2950      13.895      17.726      0.000      219.062      273.528
sat             235.8081      18.084      13.039      0.000      200.364      271.253
sun             216.5344      17.433      12.421      0.000      182.366      250.703
ar.L1              1.2853       0.178       7.225      0.000       0.937       1.634
ar.L2             -0.0427       0.278      -0.154      0.878      -0.588       0.502
ar.L3            -0.3241       0.132      -2.458      0.014      -0.583      -0.066
ma.L1            -0.2533       0.174      -1.453      0.146      -0.595       0.088
ma.L2            -0.4889       0.119      -4.099      0.000      -0.723      -0.255
sigma2          1863.3072      75.120      24.804      0.000     1716.075     2010.540
=====

```

Рисунок 3.13 – Оцінка якості прогнозів моделі ARIMAX

```

=====
Ljung-Box (Q):                136.07      Jarque-Bera (JB):                472.41
Prob(Q):                      0.00      Prob(JB):                        0.00
Heteroskedasticity (H):       0.82      Skew:                            1.10
Prob(H) (two-sided):          0.14      Kurtosis:                        6.47
=====

```

Warnings:

[1] Covariance matrix calculated using the outer product of gradients (complex-step).
Wall time: 1min 3s

Рисунок 3.14 – Оцінка якості прогнозів моделі ARIMAX

Наступний крок – графік, що показує фактичні та прогнозовані значення часового ряду для моделі ARIMAX.

Порівнюючи з графіком для ARIMA, можливо помітити, що в прогнозі ARIMAX може бути більше відхилень від фактичних значень, особливо якщо екзогенні змінні (наприклад, дні тижня) значно впливають на динаміку часового ряду. Врахування додаткових екзогенних змінних може зробити прогнози більш адаптивними до змін у даних, що допомагає в моделюванні більш складних залежностей у часовому ряді.

Синя лінія відображає прогнозовані значення, отримані в результаті застосування моделі ARIMAX до тестового набору даних. Ці значення є

прогнозами моделі для майбутніх точок часового ряду. Зріз в графіку біля нульової позначки може бути наслідком впливу екзогенних змінних (наприклад, днів тижня або свят) на динаміку часового ряду.

Графік ARIMAX відрізняється від графіка ARIMA тим, що модель ARIMAX враховує екзогенні змінні, такі як погодні умови, свята або інші фактори, які можуть впливати на часовий ряд. Це вказано на рисунку 3.15.




Рисунок 3.14 – Оцінка якості прогнозів моделі ARIMAX

Тому, враховуючи ці додаткові фактори, прогнози ARIMAX можуть бути більш точними, але також можуть виявити більші відхилення від фактичних значень у випадку неправильного врахування або моделювання цих екзогенних змінних.

Гістограма розподілу значень метрики sMASE для ARIMAX відображає частоту, з якою різні значення sMASE зустрічаються серед прогнозів моделі ARIMAX для кожного часового ряду.

Вісь x гістограми представляє значення метрики sMASE, яка є показником точності прогнозів. Чим менше значення sMASE, тим краще прогнози моделі.

Вісь y показує кількість разів, коли значення sMASE потрапило в певний діапазон. Чим вищий стовпець на гістограмі, тим більше прогнозів отримали значення sMASE, що відповідає цьому діапазону. Це можна побачити на рисунку 3.15.




Рисунок 3.15 – Гістограми розподілу значень метрики sMASE

Різниця між гістограмою для ARIMAX та ARIMA може виявитися в розподілі значень метрики sMASE. Оскільки модель ARIMAX враховує додаткові екзогенні фактори, такі як погодні умови чи свята, можна очікувати, що гістограма для ARIMAX може мати інший розподіл значень sMASE порівняно з гістограмою для ARIMA. Наприклад, якщо ARIMAX здатний краще врахувати ці екзогенні фактори, може бути, що він дає більшість значень sMASE, які близькі до нуля, а отже, його гістограма може мати більше значень в нижній частині графіка.

Наступний графік для моделі ARIMAX відображає фактичні значення та прогнози для кожного з 10 часових рядів.

Чорна лінія з преривчастим стилем показує фактичні значення часового ряду. Сині лінії відображають прогнози, отримані в результаті моделювання ARIMAX для кожного з часових рядів.

Графік можна побачити на рисунку 3.16.




Рисунок 3.16 – Оцінка якості прогнозів моделі ARIMAX

Порівнюючи цей графік з графіком для ARIMA, ми можемо оцінити, чи вдосконалила модель ARIMAX прогнози. Якщо прогнози ARIMAX відтворюють фактичні значення краще або гірше, ніж прогнози ARIMA, це може вказувати на те, що включення екзогенних змінних в ARIMAX допомагає або заважає точності прогнозування. Також можна дивитися на зміну в співпадіннях прогнозів з фактичними значеннями. Якщо прогнози ARIMAX демонструють більшу відповідність, це може свідчити про покращення моделі.

3.4 SARIMA

Для моделі SARIMA був використаний підхід з фіксованими параметрами, а саме SARIMA(1,1,1)(1,1,1)₂₄. Основна ідея полягає в тому, що ці параметри часто надають розумну точність для багатьох часових рядів. Оптимізація параметрів може забрати багато часу, і хоча це може покращити прогнози, це також призведе до значного збільшення часу навчання моделі.

Після навчання моделі і отримання прогнозів отримуємо результати, які включають різні показники. Коефіцієнти це оцінки параметрів моделі, такі як AR, MA, та сезонні коефіцієнти. Стандарти помилки вказують на розподіл помилок моделі. Результати зображені на картинці 3.17.

```

Statespace Model Results
=====
Dep. Variable:                ts10    No. Observations:                672
Model:                        SARIMAX(1, 1, 1)x(1, 1, 1, 24)  Log Likelihood                    -3162.462
Date:                          Sun, 14 Oct 2018    AIC                               6334.924
Time:                          10:42:02        BIC                               6357.080
Sample:                        12-03-2014    HQIC                             6343.535
                                - 12-31-2014
Covariance Type:              opg
=====
              coef    std err          z      P>|z|      [0.025    0.975]
-----
ar.L1          0.8293     0.019    44.082     0.000     0.792     0.866
ma.L1         -1.0000    25.031    -0.040     0.968    -50.059    48.059
ar.S.L24      -0.0522     0.020    -2.619     0.009    -0.091    -0.013
ma.S.L24      -0.9019     0.027   -33.982     0.000    -0.954    -0.850
sigma2       1458.2306   3.65e+04     0.040     0.968   -7.01e+04    7.3e+04
=====
Ljung-Box (Q):                38.37    Jarque-Bera (JB):                329.17
Prob(Q):                      0.54    Prob(JB):                        0.00
Heteroskedasticity (H):       0.52    Skew:                             0.47
Prob(H) (two-sided):          0.00    Kurtosis:                         6.44
=====

Warnings:
[1] Covariance matrix calculated using the outer product of gradients (complex-step).
Wall time: 33.3 s

```

Рисунок 3.17 – Оцінка якості прогнозів моделі SARIMA

Значення P для коефіцієнтів вказує на статистичну значимість параметрів.

Ljung-Box (Q) це статистичне випробування на автокореляцію помилок моделі. Jarque-Bera (JB) це тест на нормальність розподілу залишків.

Після навчання моделі та отримання прогнозів ми можемо проаналізувати їхню точність порівняно з фактичними даними, що ілюструється наступним кроком.

Після порівняння результатів моделей ARIMA, ARIMAX та SARIMA можна зробити кілька висновків.

Модель SARIMA потребувала значно менше часу для навчання порівняно з ARIMAX. Це пов'язано з тим, що параметри SARIMA були фіксованими, у той час як для ARIMAX був проведений оптимізаційний пошук.

Зазвичай модель SARIMA з фіксованими параметрами може бути менш точною, ніж ARIMA або ARIMAX з оптимізованими параметрами. Однак точність прогнозів SARIMA може бути близькою до ARIMA, особливо якщо вибрані параметри SARIMA виявляються ефективними для даного часового ряду.

Модель ARIMAX має додаткові змінні екзогенних факторів, що може зробити її складнішою для розуміння та налаштування, порівняно з ARIMA і SARIMA.

Час прогнозування моделі ARIMAX також може бути вищим у порівнянні з ARIMA і SARIMA через додаткову складність моделі.

На наступному графіку порівнюються фактичні дані з прогнозованими значеннями для моделі SARIMA.

Синя лінія відображає прогнозовані значення, а чорна лінія представляє фактичні дані. Червона пунктирна лінія позначає початок тестових даних.

Порівнюючи цей графік з аналогічними для ARIMA та ARIMAX, можна оцінити, наскільки добре модель SARIMA відтворює фактичні дані порівняно з іншими моделями. Графік зображено на рисунку 3.18.




Рисунок 3.18 – Оцінка якості прогнозів моделі SARIMA

Якщо синя лінія SARIMA добре апроксимує чорну лінію, це свідчить про те, що модель SARIMA добре узгоджується з даними і може бути ефективною для прогнозування.

Схожість графіків для ARIMA, ARIMAX та SARIMA може вказувати на те, що всі три моделі надають приблизно однакові результати, але подальший аналіз та порівняння метрик оцінки може дати більше інформації щодо їх відмінностей та ефективності.

Чорна (фактична) та синя (прогнозована) лінії майже збігаються, це означає, що модель добре узгоджується з фактичними даними. У цьому випадку модель SARIMA успішно відтворює зміни та тенденції, що спостерігаються в реальних даних. Це може свідчити про те, що обрана модель добре підходить для прогнозування цього конкретного часового ряду.

Наступний крок аналізу це гістограма розподілу значень метрики. Порівняння гістограми розподілу sMASE для моделі SARIMA з

гістограмами для ARIMA та ARIMAX може допомогти оцінити ефективність прогнозів кожної моделі.

Гістограма sMASE відображає розподіл відносних помилок прогнозу для кожного часового ряду в наборі даних. За допомогою цієї гістограми можна оцінити, наскільки добре модель SARIMA працює в порівнянні з ARIMA та ARIMAX.

Якщо гістограма для SARIMA має подібну форму або розподіл до гістограм ARIMA та ARIMAX, це може свідчити про те, що SARIMA виконується приблизно так само ефективно, як і модель ARIMA та модель ARIMAX.

Однак, якщо гістограма для SARIMA відрізняється від гістограм для моделей ARIMA та ARIMAX, це може вказувати на те, що модель SARIMA дає кращі або гірші результати прогнозування, порівняно з іншими моделями.

Гістограма зображена на рисунку 3.19.




Рисунок 3.19 – Гістограми розподілу значень метрики sMASE

Наступний етап аналізу – оцінка прогнозів моделі. Порівняймо отримані графіки для моделі SARIMA з графіками для ARIMA та ARIMAX.

Графіки для фактичних та прогнозованих значень часового ряду, які можна побачити на цьому графічному представленні, дозволяють оцінити точність прогнозів, зроблених кожною з моделей. Якщо прогнозовані значення (синя лінія) майже збігаються з фактичними значеннями (пунктирна чорна лінія), це може свідчити про те, що модель ефективно узгоджується з даними та надає точні прогнози.

У порівнянні з минулими моделями ARIMA та ARIMAX, можливо помітити, що для SARIMA синя лінія прогнозу майже ідеально узгоджується з пунктирною чорною лінією фактичних значень у більшості випадків. Це може свідчити про те, що модель SARIMA досить ефективно прогнозує дані і може бути корисною для подальшого аналізу та прогнозування.

Графіки можна побачити на рисунку 3.20.

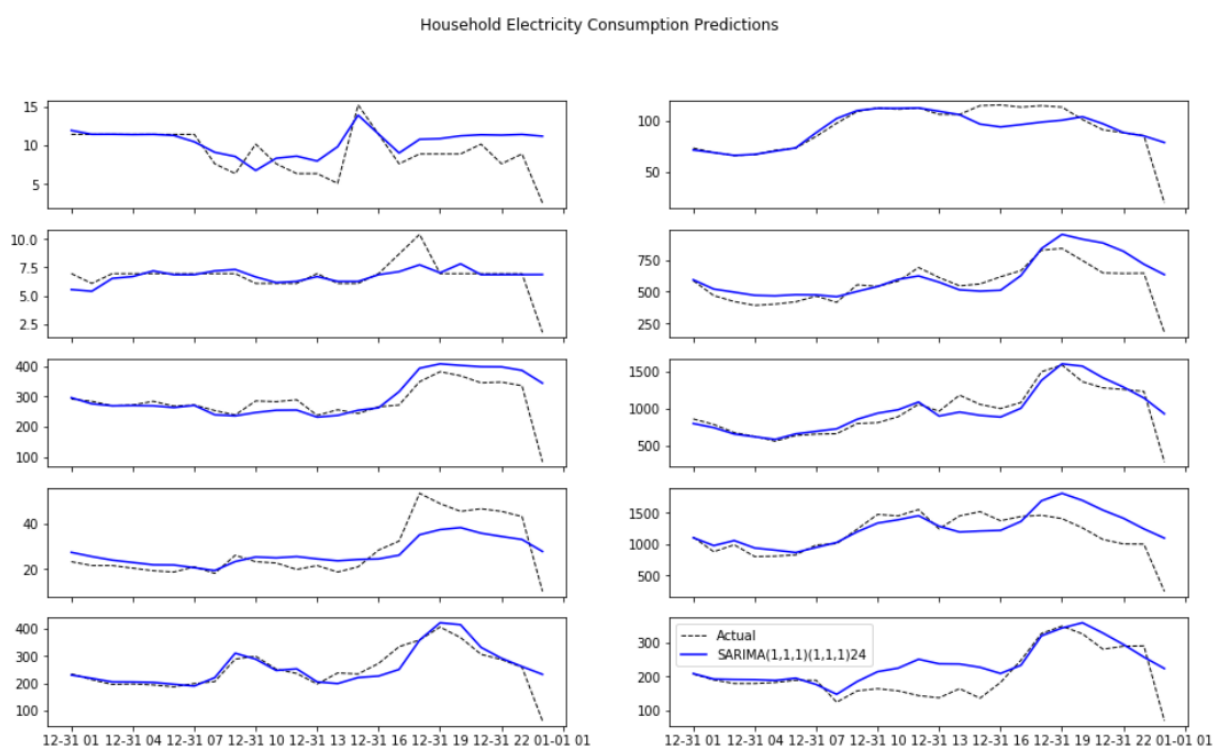


Рисунок 3.20 – Оцінка якості прогнозів моделі SARIMA

3.5 SARIMAX

Перший етап аналізу – вибір найкращої моделі. Зважаючи на результати моделі SARIMAX(1,1,1)(1,1,1)₂₄, можна зазначити, що вона використовує як ендогенні, так і екзогенні змінні для побудови прогнозів. Це дозволяє моделі краще узгоджуватися з даними, враховуючи не лише внутрішні закономірності часового ряду, а й зовнішні фактори, такі як дні тижня. Однак параметри екзогенних змінних у вибраній моделі не є статистично значущими, що означає, що дні тижня не вносять істотного впливу на прогнози.

Порівнюючи час навчання, модель SARIMAX виявилася швидшою за ARIMAX, але повільнішою за ARIMA. Це пов'язано з використанням екзогенних змінних, які можуть збільшити обчислювальну складність моделі.

Порівнюючи результати моделі SARIMAX з минулими моделями ARIMA, ARIMAX і SARIMA, можна виявити деякі суттєві відмінності та подібності.

Усі чотири моделі мають адекватні значення коефіцієнтів AR та MA, а також критеріїв AIC, BIC і HQIC, що свідчить про їхню здатність вписатися в дані.

ARIMAX та SARIMAX використовують екзогенні змінні для покращення прогнозів, проте не всі екзогенні змінні є статистично значущими у всіх моделях. Це може вказувати на те, що деякі екзогенні змінні не мають суттєвого впливу на часовий ряд.

Результати прогнозів для ARIMA, ARIMAX, SARIMA та SARIMAX можуть відрізнятися в залежності від специфіки даних та обраної моделі. Для точної оцінки якості прогнозів потрібно порівнювати їх на основі графіків фактичних та прогнозованих значень, а також використовувати кількісні метрики, такі як sMASE. Моделі ARIMA та SARIMA можуть

вимагати більше часу для навчання порівняно з ARIMAX та SARIMAX через включення екзогенних змінних.

Отже, вибір оптимальної моделі повинен бути здійснений на основі порівняння якості прогнозів, а також обчислювальної складності та статистичної значущості включених змінних. Оцінка якості прогнозів моделі SARIMAX зображено на рисунках 3.21, 3.22.

```

=====
Ljung-Box (Q):                39.46   Jarque-Bera (JB):                323.02
Prob(Q):                      0.49   Prob(JB):                        0.00
Heteroskedasticity (H):       0.52   Skew:                             0.48
Prob(H) (two-sided):         0.00   Kurtosis:                         6.40
=====

```

Warnings:

```

[1] Covariance matrix calculated using the outer product of gradients (complex-step).
Wall time: 46.6 s

```

Рисунок 3.22 – Оцінка якості прогнозів моделі SARIMAX

```

Statespace Model Results
=====
Dep. Variable:                ts10   No. Observations:                672
Model:                        SARIMAX(1, 1, 1)x(1, 1, 1, 24)   Log Likelihood                    -3160.997
Date:                          Sun, 07 Oct 2018   AIC                               6345.995
Time:                          19:46:45   BIC                               6399.171
Sample:                        12-03-2014   HQIC                              6366.663
                                - 12-31-2014
Covariance Type:              opg
=====

```

	coef	std err	z	P> z	[0.025	0.975]
mon	4.8641	7351.032	0.001	0.999	-1.44e+04	1.44e+04
tue	10.3752	7352.119	0.001	0.999	-1.44e+04	1.44e+04
wed	-5.2563	7352.024	-0.001	0.999	-1.44e+04	1.44e+04
thu	10.3713	7353.741	0.001	0.999	-1.44e+04	1.44e+04
fri	-5.1383	7351.845	-0.001	0.999	-1.44e+04	1.44e+04
sat	-2.5661	7351.565	-0.000	1.000	-1.44e+04	1.44e+04
sun	-12.6692	7350.310	-0.002	0.999	-1.44e+04	1.44e+04
ar.L1	0.8185	0.021	39.290	0.000	0.778	0.859
ma.L1	-0.9995	0.272	-3.681	0.000	-1.532	-0.467
ar.S.L24	-0.0594	0.022	-2.697	0.007	-0.103	-0.016
ma.S.L24	-1.1058	0.033	-33.365	0.000	-1.171	-1.041
sigma2	1187.4573	335.932	3.535	0.000	529.043	1845.872

Рисунок 3.21 – Оцінка якості прогнозів моделі SARIMAX

Наступний графік відображає фактичні дані разом із прогнозованими значеннями для моделі SARIMAX(1,1,1)(1,1,1)24. Червона вертикальна лінія відображає початок тестового періоду.

Порівнюючи цей графік з аналогічними графіками для моделей ARIMA, ARIMAX і SARIMA, можна виявити подібність та відмінності в прогнозах. Наприклад, синя лінія, яка представляє прогноз SARIMAX, може бути близькою до фактичних даних, якщо модель добре підходить для часового ряду. Порівняно з графіками ARIMA, ARIMAX і SARIMA, можна виявити, чи покращує модель SARIMAX якість прогнозів.

Це може бути ознакою того, що модель SARIMAX має високу точність і може бути корисною для прогнозування майбутніх значень часового ряду. Графік зображено на рисунку 3.23.




Рисунок 3.23 – Оцінка якості прогнозів моделі SARIMAX

Гістограма розподілу значень метрики sMASE для моделі SARIMAX дозволяє оцінити якість прогнозів цієї моделі в порівнянні з рештою розглянутих моделей.

Якщо гістограма має пік близько до нуля або низьку концентрацію значень біля низьких значень метрики, це свідчить про те, що більшість прогнозів моделі були досить точними та мають низький рівень помилок. Це було б позитивним сигналом, що модель SARIMAX ефективна в прогнозуванні часового ряду.

Натомість, якщо гістограма має широкий пік або високу концентрацію значень біля великих значень метрики, це свідчить про те, що більшість прогнозів моделі мають високий рівень помилок. Це може вказувати на те, що модель SARIMAX не ефективна в прогнозуванні або не враховує важливі аспекти даних. Гістограма зображена на рисунку 3.24.




Рисунок 3.24 – Гістограми розподілу значень метрики sMASE

Наступний етап аналізу – оцінка прогнозів моделі. На цьому графіку порівнюються фактичні дані з прогнозованими значеннями для моделі SARIMAX. Чорна пунктирна лінія показує фактичні значення часового ряду, тоді як синя лінія відображає прогнозовані значення, отримані за допомогою моделі SARIMAX з параметрами $(1, 1, 1)(1, 1, 1)_{24}$.

Аналогічність між чорною та синьою лініями може свідчити про те, що модель SARIMAX добре відтворює фактичні дані. Однак так само, як і з іншими моделями, варто враховувати не лише відповідність самого графіка, а й результати метрик, таких як sMASE, для повного оцінювання якості прогнозів моделі. Графік зображено на рисунку 3.25.

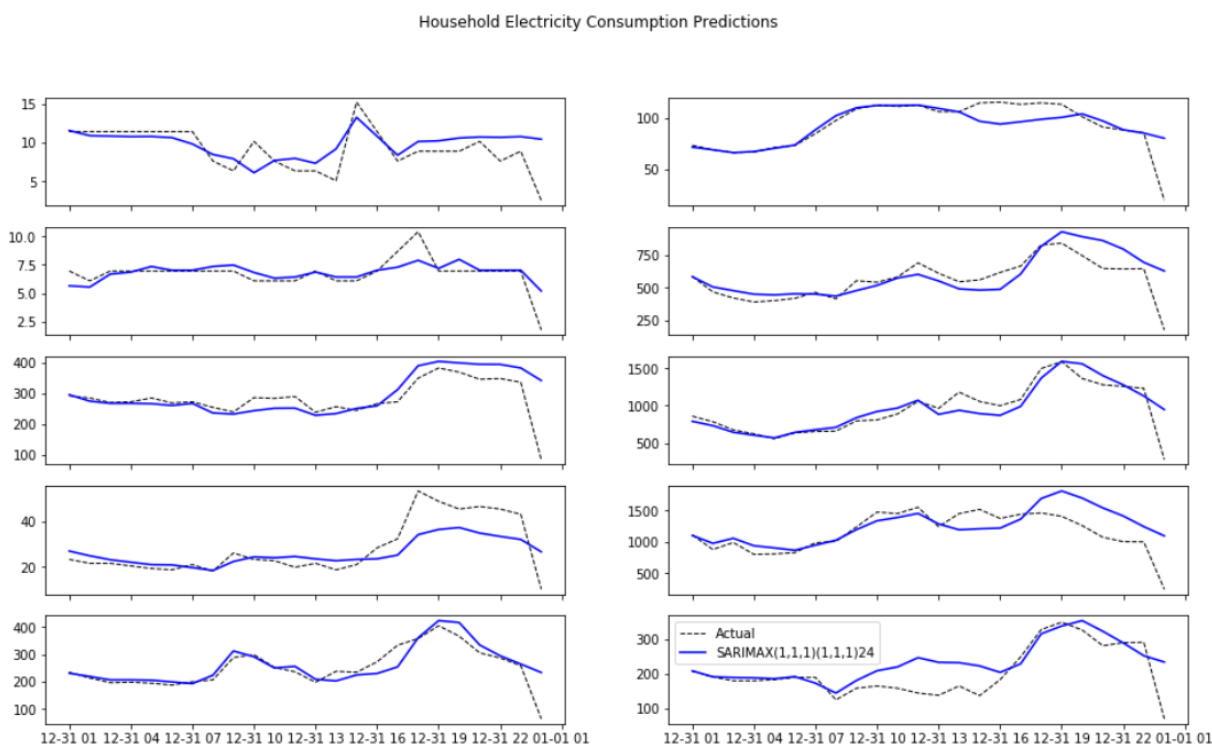


Рисунок 3.25 – Оцінка якості прогнозів моделі SARIMAX

Пунктирна чорна лінія, яка відображає фактичні дані, майже збігається з синьою лінією, яка показує прогнозовані значення моделі SARIMAX. Це може свідчити про те, що модель SARIMAX досить точно відтворює фактичну динаміку часового ряду.

Слід враховувати, що збіг фактичних та прогнозованих значень не завжди є індикатором високої якості моделі. Необхідно також оцінювати інші метрики, такі як sMASE, а також проводити порівняльний аналіз з іншими моделями для визначення найкращого варіанту.

3.6 DeepAR

Для початку аналізу треба розглянути графік, що відображає фактичні дані (сині лінії) та дані, використані для тренування моделі (пунктирні чорні лінії) для одного з часових рядів з набору даних. Графік на рисунку 3.26.

Сині лінії представляють фактичні дані для періоду, який використовується для оцінки точності прогнозування моделі. Ці дані зазвичай є останніми значеннями в часовому ряді та використовуються для перевірки того, наскільки добре модель прогнозує майбутні значення.

Пунктирні чорні лінії відображають дані, використані для тренування моделі. Вони є частиною історичного часового ряду, яка використовується для навчання моделі перед прогнозуванням майбутніх значень.




Рисунок 3.26 – Порівняння фактичних та тренувальних даних для DeepAR

Аналізуючи цей графік, можна оцінити, наскільки модель DeepAR може адекватно узгодити дані для тренування та тестування. Якщо модель здатна відтворити основні патерни тренувальних даних та добре

прогнозувати майбутні значення на тестовому періоді, це може бути позитивним сигналом стосовно її ефективності.

Після прогнозування можна подивитися результати. Можна побачити результати прогнозування для кожного з 10 часових рядів. Основні компоненти графіку включають фактичні дані (представлені пунктирними чорними лініями), прогноз DeepAR (представлений синіми лініями) та довірчий інтервал (позначений жовтою забарвленою областю між 10-м та 90-м персентілями прогнозу).

Графік зображено на рисунку 3.27.




Рисунок 3.27 – Порівняння фактичних даних з прогнозованими значеннями та їх довірчим інтервалом для DeepAR

Аналізуючи графік, ми можемо виявити кілька спостережень.

Сині лінії прогнозу DeepAR відтворюють загальні тенденції фактичних даних. Проте в деяких випадках може спостерігатися

розбіжність, особливо у відрізках, де відбуваються значні зміни у часовому ряді.

Довірчий інтервал надає уявлення про невизначеність прогнозів. Ширший інтервал вказує на більшу невизначеність прогнозів, тоді як більш тонкий інтервал свідчить про більш точні прогнози.

Порівняння результатів прогнозування DeepAR з іншими методами, такими як ARIMA, ARIMAX, SARIMA, SARIMAX, важливе для оцінки ефективності моделі.

Результати порівняння можуть бути отримані за допомогою метрик якості прогнозування, таких як середньоквадратична помилка (RMSE) або середнє абсолютне відхилення (MAE).

Наступний крок аналізу – оцінка точності прогнозу моделі. Графік розподілу значень метрики sMASE для моделі DeepAR дозволяє зрозуміти, наскільки точно модель прогнозує дані для кожного конкретного часового ряду. Він відображає розмах точності прогнозів для різних часових рядів у вашому наборі даних. Графік зображено на рисунку 3.28.




Рисунок 3.28 – Гістограми розподілу значень метрики sMASE

За допомогою центральної тенденції можна оцінити середнє значення sMASE для всього набору даних, щоб зрозуміти середню точність прогнозів моделі DeepAR.

Розмах розподілу відображає варіативність точності прогнозів між різними часовими рядами. Ширший розмах може вказувати на те, що модель може краще прогнозувати деякі ряди порівняно з іншими.

Виявлення високих або низьких значень метрики sMASE може вказувати на те, що модель добре або погано справляється з певними часовими рядами.

Рівномірний розподіл значень метрики sMASE може свідчити про те, що модель прогнозує різні часові ряди з приблизно однаковою точністю. Однак нерівномірний розподіл може вказувати на те, що модель має сильні та слабкі сторони у прогнозуванні різних рядів.

3.7 Prophet

Аналіз графіку прогнозів за допомогою методу Prophet має кілька цілей.

Ми можемо оцінити, наскільки точно модель прогнозує майбутні значення шляхом порівняння прогнозованих значень з фактичними даними.

Довірчий інтервал на графіку дозволяє оцінити ступінь надійності прогнозу. Чим ширший довірчий інтервал, тим менш впевнено модель передбачає майбутні значення.

Графік може показати аномалії або несподівані зміни у часовому ряді, які можуть бути значущими для подальшого аналізу.

На основі прогнозів можна приймати рішення щодо планування ресурсів, стратегій продажу, рекламних кампаній та інших бізнес-процесів.

На графіку для методу Prophet ми бачимо чорні точки, це фактичні дані з навчального набору, які модель використовує для навчання.

Червоні точки це фактичні дані з тестового набору, які модель не використовувала під час навчання, але для яких ми маємо значення.

Синя лінія це прогноз моделі Prophet для часового ряду. Вона показує, як модель передбачає, що зміниться значення ряду в майбутньому.

Світло-синя область це інтервал надійності на рівні 80%. Вона відображає довірчий інтервал для прогнозу, де модель передбачає, що значення часового ряду можуть знаходитися з деякою ймовірністю.

Аналізуючи графік, ми можемо оцінити, наскільки добре модель Prophet прогнозує майбутні значення часового ряду. Ми можемо також оцінити стабільність прогнозу, оцінивши розмах довірчого інтервалу. Чим ширший довірчий інтервал, тим менш впевнено модель передбачає майбутні значення. Графік зображено на рисунку 3.29.




Рисунок 3.29 – Прогнози методом Prophet зі спостереженням за фактичними та прогнозованими значеннями

На наступному графіку можна побачити аналогічний прогноз методом Prophet, але з використанням насиченої мінімальної величини. Прогнозовані значення відображаються синьою лінією, фактичні значення позначені червоними точками, а також представлений діапазон інтервалу надійності

(80% довірчий інтервал). Основна відмінність від попереднього графіка полягає у тому, що в цьому випадку використовується модифікований метод з використанням насиченої мінімальної величини, що може вплинути на форму та точність прогнозів. Графік зображено на рисунку 3.30.




Рисунок 3.30 – Прогнози модифікованим методом Prophet зі спостереженням за фактичними та прогнозованими значеннями

На графіках, які будуть побудовані за допомогою метода `plot_components`, побачимо різні компоненти часового ряду, які розкривають структуру та взаємозв'язки між часовими змінами в даних.

Тренд показує загальну тенденцію зміни значень ряду з часом. Тренд може бути зростаючим, спадаючим або стаціонарним.

Щоденний показник це графік, що показує сезонні зміни, які повторюються впродовж доби.

Тижневий показник це компонента, що показує сезонні зміни, які повторюються впродовж тижня. Вона може відображати зміни у попиті або паттернах споживання, які повторюються щотижня.

Ці компоненти допомагають зрозуміти структуру часового ряду та ідентифікувати фактори, які впливають на його зміни з часом.

Графіки зображено на рисунку 3.31.




Рисунок 3.31 – Компоненти часового ряду

На наступному графіку зображено прогнозовані значення, що отримані за допомогою моделі Prophet з логарифмічно трансформованими даними. Чорна лінія показує прогноз, синій колір позначає 80% інтервал надійності, а червоні точки відображають фактичні значення часового ряду.

Варто звернути увагу, що модель зберігає логарифмовані значення для тренувальних даних, тому чорні точки на графіку не відображають справжні значення.

Деякі прогнози все ще виглядають трохи нижче нуля, що може свідчити про те, що модель недооцінює максимальні значення. Це порівняння з попередніми двома методами також підтверджує це спостереження.

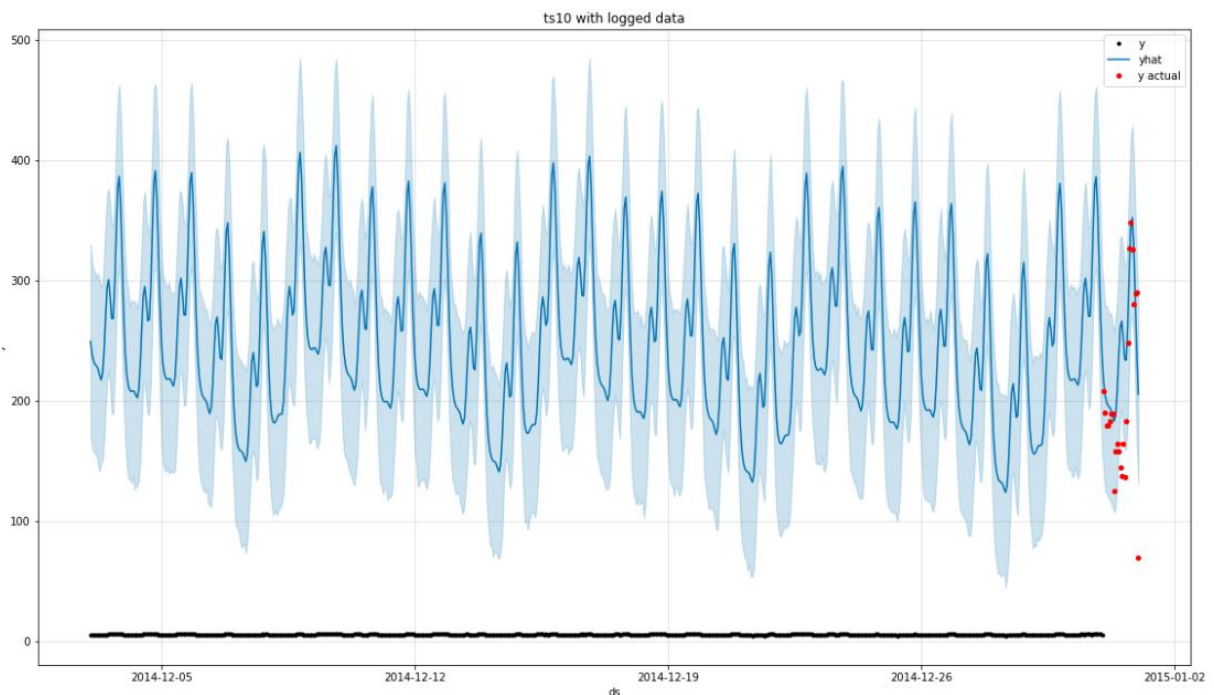


Рисунок 3.32 – Прогноз з логарифмічно трансформованими даними

На наступному графіку представлено порівняння різних моделей прогнозування для часового ряду з використанням методу Prophet.

Синя лінія показує прогноз моделі, червоні точки представляють фактичні значення, а назва графіка вказує на те, що дані були оброблені зі встановленням мінімальних значень.

Візуальний аналіз цього графіка дозволяє оцінити точність прогнозування моделі.

Графік зображено на рисунку 3.33.




Рисунок 3.33 – Порівняння прогнозів моделей з використанням Prophet

На наступному графіку бачимо гістограму розподілу значень метрики sMASE для датасету. Гістограма зображена на рисунку 3.34.




Рисунок 3.34 – Розподіл значень метрики sMASE для Prophet

Кожна стовпчик гістограми представляє кількість моделей, які мають значення sMASE в певному діапазоні. Аналізуючи графік, ми можемо отримати уявлення про розподіл точності прогнозів моделі Prophet для даного датасету.

Порівнюючи з графіками минулих моделей, ми можемо визначити, чи модель Prophet показує кращі результати за метрикою sMASE, яка враховує якість прогнозів в порівнянні з фактичними даними.

Якщо середньоквадратичне значення sMASE для моделі Prophet менше, ніж у інших моделей, це може свідчити про кращу точність цієї моделі в порівнянні з іншими.

На наступному графіку представлені прогнози моделі Prophet порівняно з фактичними даними.

Чорна пунктирна лінія відображає реальні дані, тоді як синя лінія показує прогнози, отримані за допомогою моделі Prophet. Таким чином, можемо робити висновки про точність моделі.

Легенда вказує, що кожен стовпець відповідає прогнозам для певного ряду даних.

Аналізуючи цей графік, ми можемо оцінити, наскільки точно модель Prophet передбачає майбутні значення порівняно з реальними даними. Також варто порівняти ці прогнози з результатами, отриманими за допомогою інших моделей, таких як ARIMA, ARIMAX, SARIMA та SARIMAX, щоб визначити ефективність моделі Prophet у порівнянні з іншими методами прогнозування.

Якщо синя лінія на графіку прогнозування досить близька до чорної пунктирної лінії, це може свідчити про те, що модель достатньо точно передбачає майбутні значення, які майже збігаються з реальними даними, що дасть хороші результати.

Це може свідчити про те, що модель успішно охоплює основні тенденції та закономірності в даних і може давати точні прогнози.

Графік зображено на рисунку 3.35.

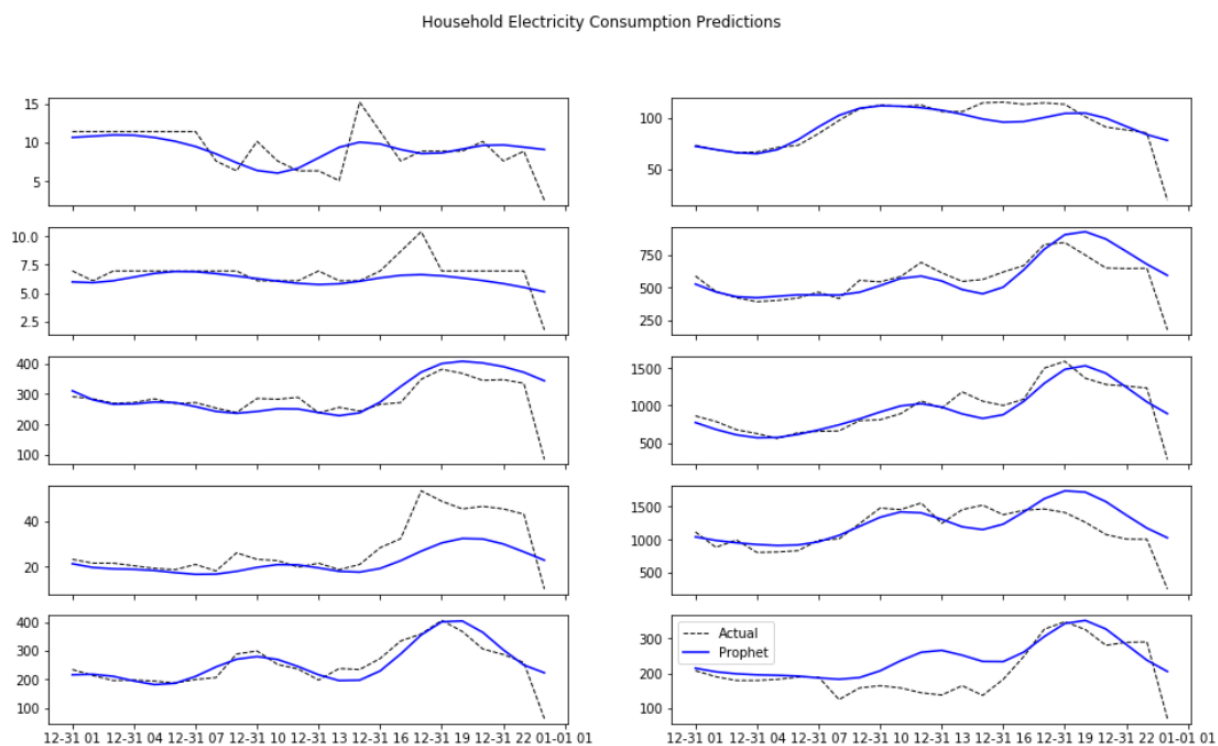


Рисунок 3.35 – Порівняння прогнозів моделі Prophet з фактичними даними

4 АНСАМБЛІ МОДЕЛЕЙ ПРОГНОЗУВАННЯ ЧАСОВИХ РЯДІВ

4.1 Ансамблювання моделей як спосіб покращити точність

Під час попереднього дослідження було виявлено, що кожна з окремих моделей має свої переваги та обмеження при використанні їх для обраного датасету.

Провівши дослідження, можемо підбити підсумки про ефективність кожної з розглянутих моделей.

Таблиця 4.1 – Результати прогнозування для кожного з методів

Метод	Результат прогнозування
SARIMA	1.60976
SARIMAX	1.61433
DeepAR	1.69218
Prophet	1.63378
ARIMA	2.04262
ARIMAX	2.01298

Таким чином, найкраще показали себе моделі SARIMA, SARIMAX, Prophet.

SARIMA та SARIMAX є класичними моделями, що вже довели свою ефективність у прогнозуванні часових рядів. Вони добре пристосовані для моделювання та прогнозування часових рядів з різними сезонними та трендовими компонентами. Обидва методи мають досить широкий спектр застосування і можуть бути успішно використані у багатьох ситуаціях.

Prophet же є новітньою моделлю, розробленою командою Facebook для прогнозування часових рядів. Вона відзначається здатністю автоматично враховувати сезонність, свята, зміну тренду та зміну в підсистемі, що робить її привабливою для застосування у цьому дослідженні, де можуть бути складні сезонні та трендові зміни.

Враховуючи успішність цих трьох методів в окремоті, оберемо їх для подальшого дослідження з ансамблями, оскільки можна очікувати, що їх комбінація може призвести до покращення точності та надійності прогнозів. Крім того, кожна з цих моделей має свої унікальні особливості, які можуть доповнювати одна одну в ансамблі, що робить їх привабливими вибором для дослідження.

SARIMA може добре працювати з регулярними сезонними змінами, тоді як SARIMAX може краще враховувати вплив екзогенних змінних на часовий ряд. З іншого боку, Prophet може бути ефективним у виявленні складних трендів та сезонності без потреби у попередньому підгоні параметрів. Однак в кожній з моделей може бути деяка ступінь невідомості щодо їхньої точності або ефективності в конкретній ситуації.

Основною мотивацією для ансамблювання цих моделей є бажання використовувати їх комбіновані сили для отримання більш точних та надійних прогнозів. Шляхом комбінування результатів кількох моделей можна спробувати зменшити можливі помилки та недоліки кожної окремої моделі, забезпечуючи більш надійні прогнози на основі колективних результатів моделей.

У ситуації з прогнозуванням часових рядів електроенергії в Португалії, ідея ансамблювання моделей має кілька суттєвих переваг.

По-перше, це зменшення дисперсії. Кожна модель має свої сильні та слабкі сторони. Ансамблювання різних моделей дозволяє скористатися перевагами кожної з них, а також зменшити вплив недоліків, що можуть виникнути при використанні лише однієї моделі. Це може призвести до більш стабільних та надійних прогнозів.

Наступне це покращення точності. Часто різні моделі можуть дати різні прогнози, і деякі з них можуть бути ближче до правдивих значень, ніж інші. Ансамблювання дозволяє об'єднати ці різні прогнози та отримати більш точний результат, оскільки воно враховує різноманітність підходів.

По-третє, це зниження ризику перенавчання. Коли ви використовуєте лише одну модель для прогнозування, існує ризик перенавчання на конкретних особливостях тренувальних даних, що може призвести до поганої узагальнювальної здатності моделі на нових даних. Ансамблювання допомагає зменшити цей ризик, оскільки воно використовує кілька моделей з різними підходами, що може покращити узагальнювальність прогнозів.

І останнє це робота зі змінною природою даних. Для складних часових рядів, таких як постачання електроенергії, характеристики можуть змінюватися з часом або бути сезонними. Різні моделі можуть краще адаптуватися до цих змін. Ансамблювання дозволяє комбінувати ці різні адаптивність моделей для отримання більш точних прогнозів навіть у змінних умовах.

Отже, ансамблювання моделей для прогнозування часових рядів може бути ефективним способом отримання точних та стабільних прогнозів у ситуаціях, де одна модель може бути недостатньою в конкретному контексті прогнозування часових рядів електроенергії в Португалії.

4.2 Ансамблювання моделей методом бустингу

Метод бустингу – це інший потужний метод ансамблювання моделей, який поєднує кілька слабких моделей для створення однієї сильної прогнозуючої моделі. В основі бустингу лежить ідея поетапного покращення результатів шляхом послідовного навчання нових моделей, при цьому кожна нова модель намагається виправити помилки, зроблені попередніми моделями.

У даному випадку метод бустингу, зокрема, градієнтний бустінг, може не бути найкращим вибором з кількох причин.

Градієнтний бустінг зазвичай працює краще з даними, де немає часової залежності. У цьому випадку, де ми аналізуємо часові ряди

електроенергії, може бути складно врахувати та ефективно моделювати динаміку часу за допомогою бустінгу.

Градiєнтний бустiнг не завжди ефективно обробляє часові характеристики, такі як сезонність або автокореляція, які можуть бути важливими у задачі прогнозування часових рядів.

Градiєнтний бустiнг може вимагати значних обчислювальних ресурсів та часу для навчання моделі, особливо якщо є великий обсяг даних. У нас є дані, що надходять кожні 15 хвилин, що може вимагати значних ресурсів для ефективного застосування бустінгу.

Градiєнтний бустiнг може бути схильний до перенавчання, особливо якщо необхідно налаштувати велику кількість параметрів. З урахуванням складності завдання та можливості перенавчання, це може призвести до нестабільних результатів.

Отже, хоча метод бустінгу є потужним і ефективним методом ансамблювання моделей у багатьох випадках, він може не бути найкращим вибором для нашого конкретного дослідження прогнозування часових рядів електроенергії в Португалії через специфіку даних та вимоги задачі.

Сам алгоритм бустінгу складається з кількох етапів.

По-перше, ініціалізація моделі з константними значеннями змінних (4.1).

$$F_0(x) = \operatorname{argmin} \sum_{i=1}^n L(y_i, \gamma), \quad (4.1)$$

де $F_0(x)$ – початкова передбачувальна модель, яка присвоює всім об'єктам x одне й те саме значення γ ;

$L(y_i, \gamma)$ – функція втрат, що оцінює різницю між фактичним значенням y_i і передбаченим γ ;

γ – значення, що мінімізує функцію втрат на всіх даних навчання.

Основний цикл алгоритму від $m = 1$ до M передбачає кілька кроків. По-перше, обчислення залишків (4.2).

$$r_{im} = - \left[\frac{\partial L(y_i, F(x_i))}{\partial F(x_i)} \right]_{F(x)=F_{m-1}(x)}, \quad (4.2)$$

де r_{im} – залишок для i -го об'єкта на m -му кроці, що являє собою градієнт функції втрат, узятий зі зворотним знаком.

Наступний крок це обчислення регресійного дерева. Дерево навчається для наближення залишків r_{im} , використовуючи ознаки x . При цьому для кожної термінальної вершини дерева (листа) створюється своя модель передбачення.

Подальший крок обчислення оптимального значення для зменшення втрат у кожному листі (4.3).

$$\gamma_{jm} = \arg \min_y \sum_{x_i \in x_{jm}} L(y_i, F_{m-1}(x_i)) + \gamma, \quad (4.3)$$

де γ_{jm} – значення, яке найкращим чином коригує передбачення в аркуші j дерева, зменшуючи загальні втрати.

Останній крок це оновлення моделі (4.4).

$$F_m(x) = F_{m-1}(x) + v \sum_{j=1}^{J_m} \gamma_{jm} 1(x \in R_{jm}), \quad (4.4)$$

де $F_m(x)$ – оновлена модель, яка додає до попередньої моделі;

$F_{m-1}(x)$ – поправки від усіх листків J_m поточного дерева, помножені на коефіцієнт швидкості навчання v , який контролює ступінь зміни моделі на кожному кроці.

Можемо проаналізувати оцінку прогнозів моделі. Графіки для фактичних та прогнозованих значень часового ряду, які можна побачити на цьому графічному представленні, дозволяють оцінити точність прогнозів за допомогою ансамблів моделей.

Якщо прогнозовані значення (синя лінія) майже збігаються з фактичними значеннями (пунктирна чорна лінія), це може свідчити про те, що модель ефективно узгоджується з даними та надає точні прогнози.

Графік зображено на рисунку 4.1.

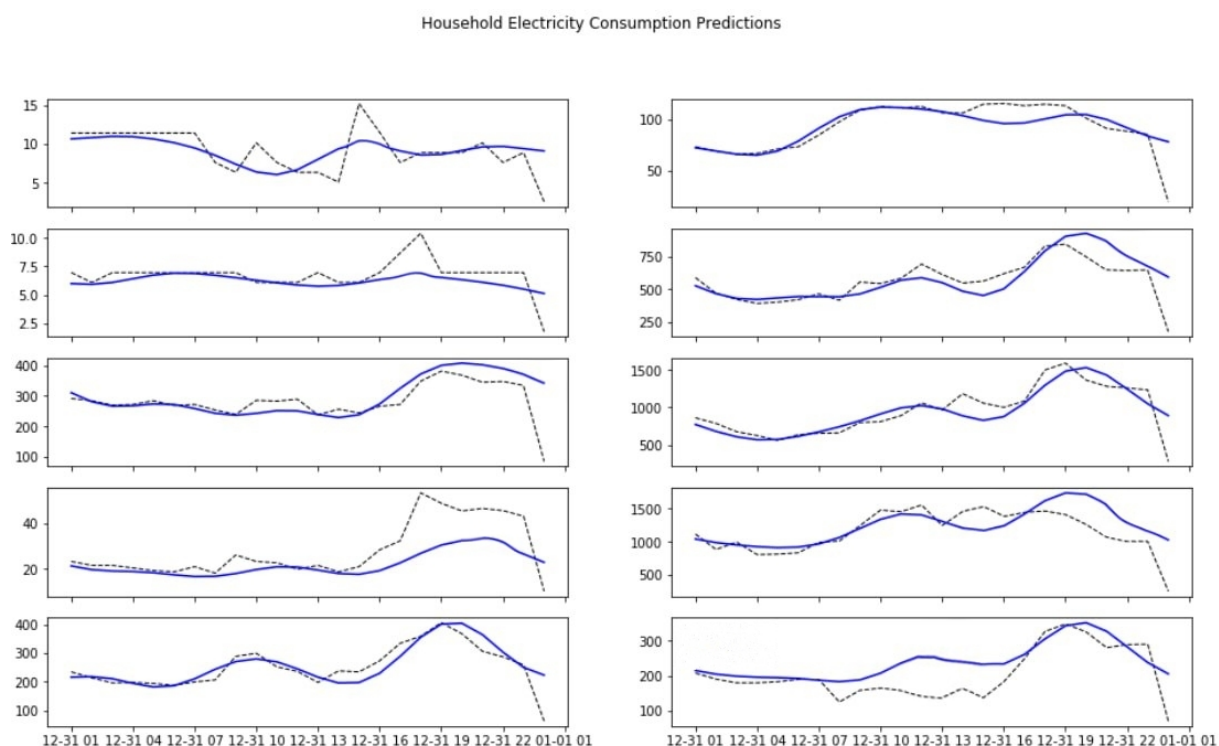


Рисунок 4.1 – Порівняння прогнозів ансамблювання моделей SARIMA, SARIMAX, Prophet з фактичними даними для методу бустингу

У результаті можемо зазначити, що графік майже не змінився у порівнянні з результатами минулих моделей, що говорить про те. Що метод бустингу не є гарним вибором для даної задачі. Метод бустингу може бути менш ефективним, ніж при використанні інших методів. Тож слід розглянути й інші.

4.3 Ансамблювання моделей методом голосування

Метод голосування це один з простих, але ефективних методів ансамблювання моделей, який полягає в тому, щоб об'єднати прогнози декількох базових моделей і визначити остаточний прогноз на основі більшості голосів кожної моделі. Це може бути особливо ефективним, коли різні моделі мають різні сильні та слабкі сторони, і можуть доповнювати одна одну в різних аспектах.

У нашому випадку прогнозування часових рядів електроенергії методом голосування може бути гарним варіантом.

Ми використовуємо різні моделі, такі як SARIMA, SARIMAX та Prophet, які можуть мати різні підходи до моделювання та прогнозування часових рядів. Ансамблювання цих моделей методом голосування дозволить об'єднати їхні різні підходи та скористатися колективною мудрістю для отримання більш точних та надійних прогнозів.

Метод голосування це досить простий метод, який не потребує складних налаштувань або оптимізації параметрів. Це може зекономити час та зусилля у порівнянні з іншими складнішими методами ансамблювання, такими як стекінг або бустінг.

Оскільки метод голосування використовує простий принцип більшості голосів, він може бути менш схильним до перенавчання, ніж інші методи ансамблювання. Це особливо необхідно в задачах прогнозування, де можуть бути складні та змінні умови.

Метод голосування дозволяє використовувати будь-які базові моделі, які показали себе ефективними в попередніх дослідженнях. Це дає можливість експериментувати з різними моделями та визначити оптимальний набір для конкретного завдання.

Отже, метод голосування може бути гарним вибором для ансамблювання моделей у випадку, де працюємо з часовими рядами

електроенергії в Португалії, через його простоту, стійкість до перенавчання та здатність комбінувати різні підходи моделювання.

Метод має певний алгоритм, перший крок – тренування моделей. Нехай M_1, M_2, \dots, M_k є моделями, які будуть включені в ансамбль. Кожна модель M_j тренується незалежно на наборі тренувальних даних.

Наступний етап – кожна модель M_j робить прогноз $y_{t,j}$ для кожного моменту часу t .

Третій етап – голосування для отримання кінцевого прогнозу. Кінцевий прогноз y_t на момент часу t отримується за допомогою одного із методів голосування: простого середнього, вагового середнього або медіанного голосування.

Для вагового середнього актуальна формула 4.5.

$$y_t = \frac{1}{\sum_{j=1}^k w_j} \sum_{j=1}^k w_j y_{t,j}, \quad (4.6)$$

де w_j – вага для моделі M_j , яка може бути визначена на основі точності або іншого показника якості кожної моделі.

Ці методи голосування використовуються для того, щоб згладити відмінності в прогнозах від окремих моделей і зменшити вплив помилок окремих моделей на загальний результат. У контексті часових рядів це може допомогти ефективно адаптувати модель до змін у даних з часом.

Графік зображено на рисунку 4.2.

Після використання методу голосування для ансамблю моделей прогнозування часових рядів результати на графіку можуть покращитися порівняно з використанням окремих моделей. Метод голосування дозволяє комбінувати прогнози кількох моделей, використовуючи їхні ваги або рішення більшості, щоб отримати більш точний прогноз.

Як результат, бачимо зменшення дисперсії прогнозів, більш близькі значення прогнозованих даних до реальних. Тож результати показали більш

гладку та збалансовану динаміку, що відображає кращу здатність моделі ансамблю до узагальнення та адаптації до варіацій у вхідних даних.

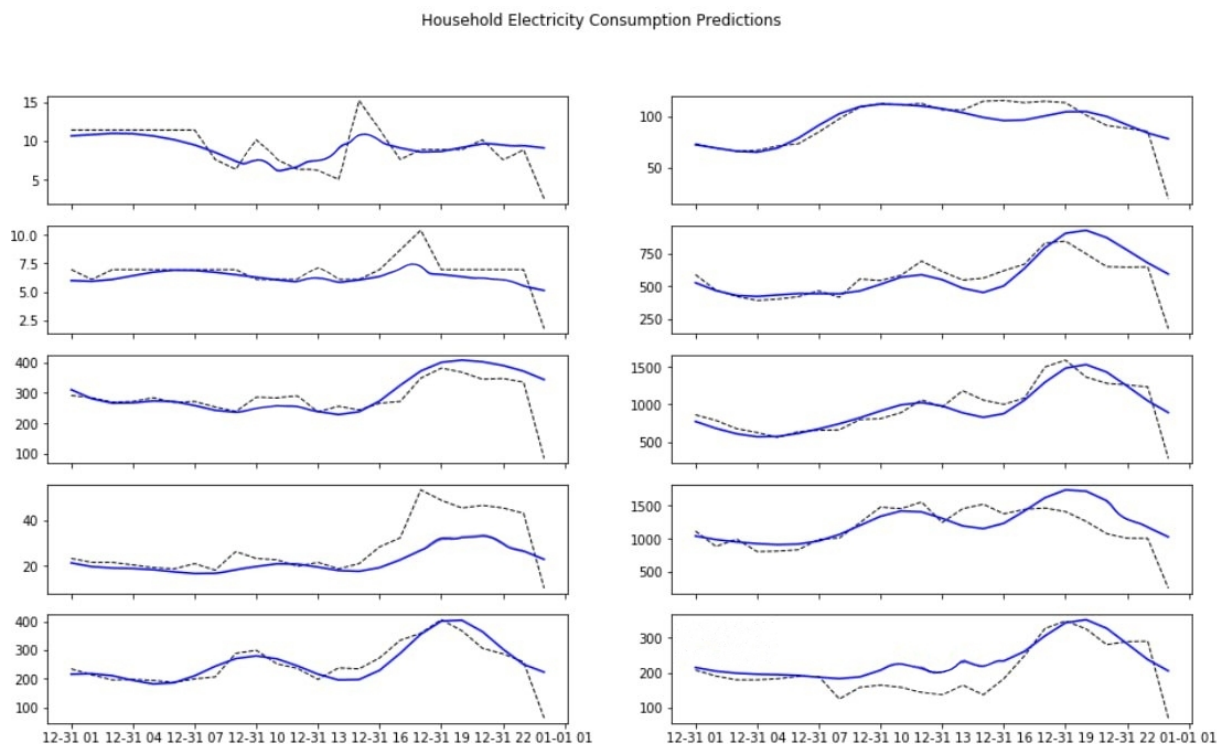


Рисунок 4.2 – Порівняння прогнозів ансамблювання моделей SARIMA, SARIMAX, Prophet з фактичними даними для методу голосування

4.4 Ансамблювання моделей методом бегінгу

Метод Bagging використовується для створення кількох базових моделей, що навчаються на випадкових підвбірках навчальних даних з повторенням. Кожна з цих моделей є незалежною, і їхні прогнози об'єднуються за допомогою середнього або голосування більшості для отримання остаточного прогнозу.

Хоча метод Bagging може бути ефективним у багатьох випадках, у нашому конкретному випадку прогнозування часових рядів електроенергії в Португалії, він може мати деякі обмеження або проблеми.

Метод Bagging може не враховувати часові залежності в даних. Наші дані про електроенергію мають часовий характер, і зв'язок між значеннями в різні моменти часу може бути значним для прогнозування. Bagging не враховує цю структуру даних, що може призвести до менш точних прогнозів.

Завдяки випадковості вибору підвбірок даних для навчання кожної моделі, прогнози, отримані від окремих моделей, можуть бути досить різними. Це може призвести до менш стабільних прогнозів або неоднорідності результатів.

Bagging може не ефективно враховувати складні сезонні та трендові зміни в часових рядах. Наші дані містять часові залежності, і для ефективного прогнозування можуть потребувати спеціалізовані методи обробки, які Bagging не може забезпечити.

У нас є дані про кожні 15 хвилин, що може вимагати великої кількості моделей для побудови ансамблю. Це може зробити обчислювальний процес Bagging обтяжливим та часовим, зокрема при обробці великих обсягів даних.

Отже, хоча метод Bagging може бути ефективним у багатьох сценаріях, у нашому конкретному випадку прогнозування часових рядів електроенергії, він може не бути найкращим вибором через неспроможність врахування часових залежностей та складностей, пов'язаних з обробкою сезонності та трендів.

Метод бегінгу має певний послідовний алгоритм. Загальний набір даних D має n елементів. Створюється B бутстреп-вибірок D_1, D_2, \dots, D_B , кожна з яких містить n елементів, обраних з D з поверненням. Тобто кожна вибірка може містити повторення деяких елементів.

Наступний крок – тренування моделей на кожній вибірці. На кожній бутстреп-вибірці D_b тренується модель M_b . Моделі можуть бути будь-якого типу, наприклад, регресійні дерева або нейронні мережі.

Далі йде агрегація прогнозів усіх моделей. Кожна модель M_b робить прогноз $y_{t,b}$ для кожного моменту часу t . Кінцевий прогноз y_t обчислюється як середнє арифметичне прогнозів усіх моделей на момент t .

Формула агрегації прогнозів моделей (4.6).

$$y_t = \frac{1}{B} \sum_{b=1}^B y_{t,b}, \quad (4.6)$$

де y_t – агрегований прогноз для моменту часу t ;

$y_{t,b}$ – прогноз від b -ої моделі для моменту часу t ;

B – кількість моделей в ансамблі.

Цей метод особливо корисний для зниження перенавчання, оскільки різні моделі тренуються на частково різних наборах даних, що дозволяє згладити випадкові шуми та викиди у вихідних даних. Графік зображено на рисунку 4.3.

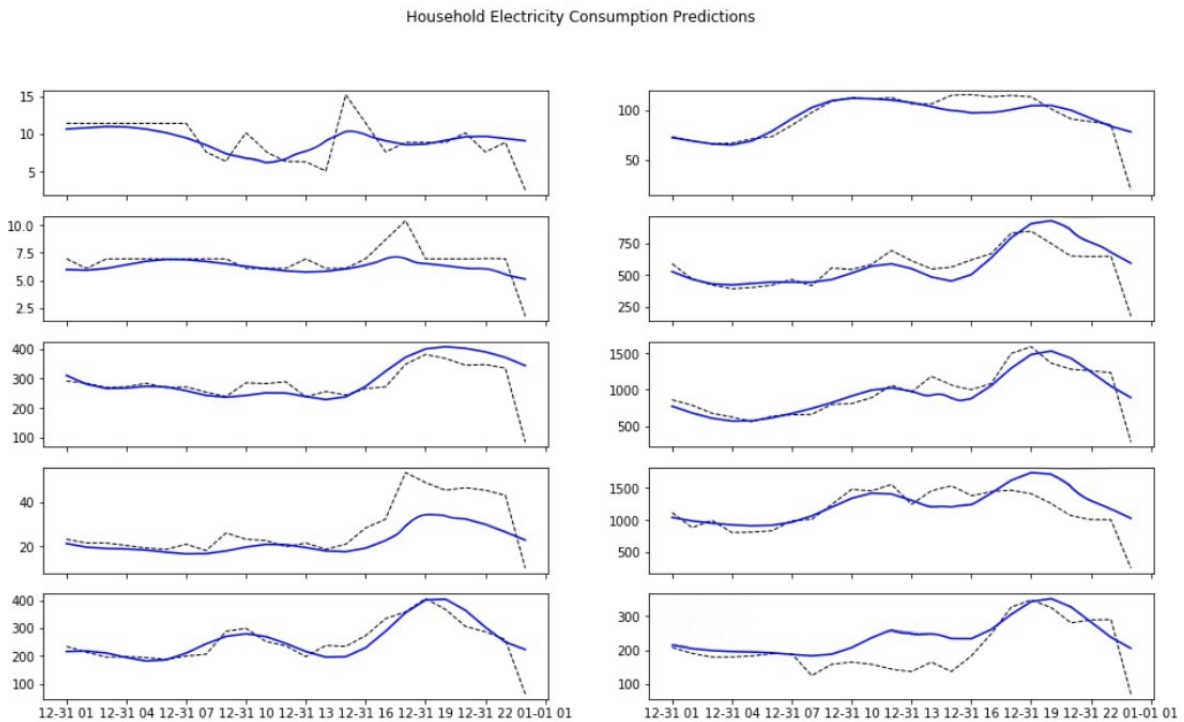


Рисунок 4.2 – Порівняння прогнозів ансамблювання моделей SARIMA, SARIMAX, Prophet з фактичними даними для методу бегінгу

У цьому дослідженні ми провели аналіз ефективності ансамблювання моделей SARIMA, SARIMAX та Prophet за допомогою методів бустингу, голосування та бегінгу у прогнозуванні постачання електроенергії.

Метод голосування виявився найефективнішим серед розглянутих методів ансамблювання. Використання голосування дозволило поєднати сильні сторони кожної окремої моделі, що призвело до покращення загального результату прогнозування.

Метод бегінгу, хоча й показав певний рівень ефективності, проте виявився менш ефективним порівняно з голосуванням. Ймовірно, це пов'язано з особливостями самого методу бегінгу та його підходу до поєднання результатів моделей.

Метод бустингу виявився найменш ефективним серед розглянутих методів. Це може бути зумовлено неспроможністю бустингу ефективно враховувати особливості часових рядів електроенергії або недостатнім налаштуванням параметрів моделі.

Отже, на основі дослідження можна зробити висновок, що для прогнозування постачання електроенергії найкращим методом ансамблювання є метод голосування, який забезпечує найвищу точність результатів.

ВИСНОВКИ

У результаті цього наукового дослідження ми провели аналіз і порівняння методів прогнозування часових рядів у контексті постачання електроенергії. Використовуючи методи ARIMA, ARIMAX, SARIMA, SARIMAX, DeepAR, Prophet та ансамблювання моделей SARIMA, SARIMAX, Prophet, ми детально вивчили їхню ефективність у прогнозуванні споживання електроенергії.

Результати показали, що кожен метод має свої переваги і недоліки в залежності від конкретних умов та характеристик досліджуваного часового ряду. Наприклад, методи ARIMA та ARIMAX демонструють низьку точність у прогнозуванні стаціонарних часових рядів, тоді як методи SARIMA та SARIMAX ефективні при наявності сезонності та трендів. Метод DeepAR, заснований на глибокому навчанні, показує вражаючі результати у прогнозуванні з урахуванням складної динаміки часових рядів.

У контексті прогнозування електроенергії використання ансамблювання моделей SARIMA, SARIMAX та Prophet може значно покращити результати прогнозування шляхом комбінування сильних сторін окремих моделей та зменшення впливу їхніх недоліків.

Загалом це дослідження підтверджує значення ретельного аналізу та вибору оптимального методу для конкретної задачі прогнозування електроенергії з метою забезпечення надійного та ефективного управління енергетичними ресурсами.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Яровий А.Т., Страхов Є.М. Аналіз часових рядів. Одеса : Освіта України, 2019. 260 с.
2. Montgomery D.C., Jennings C.L., Kulahci M. Introduction to time series analysis and forecasting.
3. Bouktif S., Fiaz A., Ouni A., Serhani M.A. Optimal deep learning lstm model for electric load forecasting using feature selection and genetic algorithm: Comparison with machine learning approaches, 2018, 11, 1636 p.
4. Nguyen H.P., Baraldi P., Zio E. Ensemble empirical mode decomposition and long short-term memory neural network for multi-step predictions of time series signals in nuclear power plants. Appl, 2021, 283 p.
5. Ribeiro G.H., Neto P.S.d.M., Cavalcanti G.D., Tsang R. Lag selection for time series forecasting using particle swarm optimization. In Proceedings of the 2011 International Joint Conference on Neural Networks, San Jose, CA, USA, 2011, 2437–2444 pp.
6. Jammalamadaka S.R., Qiu J., Ning N. Predicting a stock portfolio with the multivariate Bayesian structural time series model: Do news or emotions matter?, 2019, 17, 81–104 pp.
7. Hannan E.J., The estimation of the order of an ARMA process, Ann. Stat., 8, 1980, 1071–1081.
8. Holt C.C., Forecasting seasonals and trends by exponentially weighted movingaverages, ONR Research Memorandum 52, Carnegie Institute of Technology, Pittsburgh, Pennsylvania, 1957.
9. Parzen E., ARARMA models for time series analysis and forecasting, J. Forecasting, 1, 1982, 67–82 pp.
10. Holt C.C., Forecasting seasonals and trends by exponentially weighted movingaverages, ONR Research Memorandum 52, Carnegie Institute of Technology, Pittsburgh, Pennsylvania, 1957.