



УДК 621.311.16

[https://doi.org/10.70769/2181-2284.МЕ.2\(23\).2026.36](https://doi.org/10.70769/2181-2284.МЕ.2(23).2026.36)

ФОРМИРОВАНИЕ ПРИЗНАКОВОГО ПРОСТРАНСТВА ДЛЯ СЕГМЕНТАЦИИ РЕЖИМОВ ЭНЕРГОПОТРЕБЛЕНИЯ В АРКТИЧЕСКИХ УСЛОВИЯХ

Н.А. Нагибин

Мурманский Арктический университет, Россия, 183010, г. Мурманск, ул. Спортивная, д. 13

*e-mail: nagibin.1995@yandex.ru

Аннотация. В работе решается задача формирования признакового пространства для устойчивой сегментации профилей нагрузки арктических энергосистем, где экстремальная климатическая нестационарность и полярные циклы нарушают предположения о классической сезонности. На основе данных трёх объектов за 2023–2025 гг. сформирован вектор из 36 признаков. Кластерный анализ выделил 4–6 физически интерпретируемых режимов с метрикой Silhouette 0,68–0,74. Внутрикластерная дисперсия снижена на 40–60% относительно единой выборки, что создаёт эмпирическую базу для локального моделирования.

Ключевые слова: арктические энергосистемы, признаковое пространство, кластеризация режимов, сегментация нагрузки, нестационарность, SCADA-данные

UDC 621.311.16

CONSTRUCTION OF A FEATURE SPACE FOR ENERGY CONSUMPTION REGIME SEGMENTATION UNDER ARCTIC CONDITIONS

N.A. Nagibin *

Murmansk Arctic University, Russia, 183010, Murmansk, Sportivnaya St., 13

*e-mail: nagibin.1995@yandex.ru

Abstract. This paper addresses the challenge of constructing a feature space for robust segmentation of load profiles in Arctic power systems, where extreme climatic non-stationarity and polar cycles invalidate assumptions of classical seasonality. Using data from three facilities collected between 2023 and 2025, a 36-dimensional feature vector was developed. Cluster analysis revealed 4–6 physically interpretable operating regimes, with Silhouette coefficients ranging from 0.68 to 0.74. Intra-cluster variance decreased by 40–60% compared to a single aggregated dataset, providing an empirical foundation for localized load modeling.

Key words: Arctic power systems, feature space, regime clustering, load segmentation, non-stationarity, SCADA data.

Введение

Прогнозирование пиковых нагрузок в изолированных арктических сетях сталкивается с фундаментальной проблемой: сезонные колебания температуры достигают 50°C, суточные перепады — 20–30°C, а полярные дни и ночи формируют профили потребления, не описываемые стандартными календарными компонентами [1, 2]. Традиционные методы декомпозиции, опирающиеся на слабую нестационарность, систематически дают ошибки на границах режимов [4]. Цель работы — сформировать и верифицировать признаковое пространство, обеспечивающее устойчивую сегментацию арктических профилей на интерпретируемые режимы. Фокус сделан на экспериментальных результатах анализа реальных данных трёх объектов за 2023–2025 гг.



Методы и материалы

Экспериментальная база включает почасовые данные трёх объектов: ПС «Мурманск-Восточная» (22 МВт), п. Ревда (1,2 МВт), ПС «Подольск» (45 МВт). Период наблюдений: январь 2023 — декабрь 2024 (17520 наблюдений на объект).

Для каждого наблюдения сформирован вектор из 36 признаков, сгруппированных в четыре категории:

- Лаги нагрузки (8): сдвиги 1, 2, 3, 6, 12, 24 ч; значение на тот же час предыдущего дня и недели.
- Метеопараметры (6): температура, влажность, скорость ветра, давление, интенсивность и тип осадков.
- Производные признаки (10): ΔT и ΔLoad за 1, 3, 6, 24 ч; скользящие средние температуры (6 ч) и нагрузки (12, 24 ч); отклонение текущей температуры от суточного максимума.
- Контекстуальные признаки (12): час суток, день недели, тип дня, месяц, квартал, неделя года, бинарные признаки «полярный день/ночь», длина светового дня, «отопительный период», «межсезонный переход», индекс экстремальности погоды.

Данные нормализованы (Z-score), пропуски интерполированы с учётом суточной периодичности. Сегментация выполнена алгоритмами k-means и DBSCAN. Качество оценивалось по Silhouette и Davies-Bouldin. Визуализация проведена через PCA и t-SNE.

Результаты

Корреляционный анализ Пирсона показал, что традиционные календарные индексы имеют связь с нагрузкой ниже 0,3, тогда как температурные градиенты и среднесрочные лаги превышают 0,65 (таблица 1).

Таблица 1.

Топ-10 корреляций признаков с целевой переменной (нагрузка)

Table 1.

Top-10 feature correlations with the target variable (load)

Показатели	Тип	Описание	Коэффициент корреляции
ΔT 6h	Производный	Градиент температуры за 6 ч	−0,72
Load lag 24h	Лag нагрузки	Нагрузка 24 ч назад	0,68
T_{ma} 6h	Производный	Скользящая средняя T за 6 ч	−0,66
ΔLoad 24h	Производный	Прирост нагрузки за 24 ч	0,65
Load lag 168h	Лag нагрузки	Нагрузка 168 ч назад (неделя)	0,63
T_{dev_dmax}	Производный	Отклонение T от суточного максимума	−0,58
Wind_speed	Метеопараметр	Скорость ветра, м/с	−0,41
Load_ma_12h	Производный	Скользящая средняя нагрузки, 12 ч	0,38
Heat_period	Контекстуальный	Бинарный: отопительный период	−0,35
Day_of_week	Контекстуальный	День недели (0 = пн, 6 = вс)	0,18

Кластерный анализ устойчиво выделил 4–6 режимов потребления. Метрика Silhouette составила 0,68–0,74, Davies-Bouldin — 0,62–0,78. Физическая интерпретация кластеров подтверждена средними профилями и метеоусловиями (таблица 2).

Таблица 2.

Характеристики выделенных режимов (на примере ПС «Мурманск-Восточная»)

Table 2.

Regime characteristics derived from clustering analysis (illustrated by "Murmansk-Vostochnaya")

Режим	N, ч	T ср., °C	Нагр. ср., МВт	Нагр. макс., МВт	Silhouette	Снижение дисп.	Характеристики
1 — Арктическая зима (экстремальная)	1 420	-24,3	20,1	22,0	0,74	-58%	T < -20°C, высокий ветер, макс. отопит. нагрузка
2 — Зима стандартная	3 280	-12,7	18,3	21,5	0,71	-52%	T -20...-5°C; устойчивый отопительный период
3 — Межсезонье	2 640	-3,1	15,6	19,2	0,68	-44%	T -5...+5°C; высокая нестационарность
4 — Полярный день	3 810	+11,2	11,4	15,8	0,72	-47%	T > +5°C; длинный световой день, мин. отопление
5 — Переходный режим	2 350	+1,4	13,9	18,4	0,70	-40%	Быстрые перемены погоды; концептуальный дрейф

Проекция в пространстве главных компонент демонстрирует чёткую сепарацию режимов (рисунок 1).




Рис. 1. Проекция кластеров в пространстве главных компонент (ПС «Мурманск-Восточная», 2023–2024; Silhouette = 0,68–0,74)

Fig. 1. Projection of clusters onto principal component space (substation "Murmansk-Vostochnaya", 2023–2024; Silhouette = 0.68–0.74)



Обсуждение

Выделенные режимы показывают, что арктическое энергопотребление управляется термодинамическими градиентами и световыми циклами, а не календарной периодичностью. Именно поэтому модели экспоненциального сглаживания [4] систематически теряют точность на границах режимов. Сегментация на 4–6 кластеров решает проблему: внутри каждого режима дисперсия нагрузки падает на 40–60% (рисунок 2), создавая однородные подвыборки для обучения. Практическая ценность заключается в физической интерпретируемости каждого кластера: операторы могут заранее настраивать коэффициенты безопасности, а алгоритмы адаптации — отслеживать концептуальный дрейф при изменении структуры потребителей [3, 5]. Ограничения связаны с зависимостью от точности метеоданных и необходимостью ежемесячного обновления границ кластеров. Тем не менее, сформированное пространство обеспечивает устойчивую основу для трёхкомпонентной архитектуры прогнозирования.




Рис.2. Снижение вариальности нагрузки по объектам (коэффициент вариации до и после сегментации)

Fig. 2. Reduction in load variability across facilities (coefficient of variation before and after segmentation)

Заключение

Сформировано и верифицировано признаковое пространство из 36 признаков, обеспечивающее устойчивую сегментацию арктических профилей на 4–6 интерпретируемых режима. Корреляционный анализ подтвердил неэффективность календарных индексов ($r < 0,3$) и доминирование температурных градиентов и лагов 6–24 ч ($r > 0,65$). Кластеризация достигла Silhouette 0,68–0,74 и снижения внутрикластерной дисперсии на 40–60%, что устраняет гетероскедастичность ряда. Выделенные режимы создают эмпирическую базу для локального моделирования и адаптивных систем управления резервами статьи.

Литература

1. Hong T., Fan S. Probabilistic electric load forecasting: A tutorial review // International Journal of Forecasting. – 2016. – Vol. 32, № 3. – P. 914–938.
2. Andersson L., Alvehag K., Söder L. Reliability considerations for microgrids in remote areas // IEEE Transactions on Smart Grid. – 2018. – Vol. 9, № 4. – P. 3137–3145.
3. Gama J., Žliobaitė I., Bifet A., et al. A survey on concept drift adaptation // ACM Computing Surveys. – 2014. – Vol. 46, № 4. – Article 44.
4. Taylor J.W. Short-term electricity demand forecasting using double seasonal exponential smoothing // Journal of the Operational Research Society. – 2003. – Vol. 54, № 8. – P. 799–805.
5. Arrieta A.B., Díaz-Rodríguez N., del Ser J., et al. Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges // Information Fusion. – 2020. – Vol. 58. – P. 82–115.