

Поиск ключевых управляющих параметров для оперативного прогноза полного электронного содержания ионосферы

**А.В. Жуков, Д.Н. Сидоров, А.А. Мыльникова,
Ю.В. Ясюкевич**

ИСЗФ СО РАН

{d.sidorov, yasukevich, manna, zhukovaleksei}@iszf.irk.ru

Всероссийская открытая ежегодная конференция "Современные проблемы дистанционного зондирования Земли из космоса"
ИКИ РАН, Москва 13-17.11.2017

Содержание доклада

- 1 Постановка задачи оперативного прогноза ПЭС
- 2 Входные данные
- 3 Основные этапы моделирования
- 4 Информативность прогнозных параметров
- 5 Результаты прогнозирования
- 6 Выводы

Содержание доклада

- 1 Постановка задачи оперативного прогноза ПЭС
- 2 Входные данные
- 3 Основные этапы моделирования
- 4 Информативность прогнозных параметров
- 5 Результаты прогнозирования
- 6 Выводы

Содержание доклада

- 1 Постановка задачи оперативного прогноза ПЭС
- 2 Входные данные
- 3 Основные этапы моделирования
- 4 Информативность прогнозных параметров
- 5 Результаты прогнозирования
- 6 Выводы

Содержание доклада

- 1 Постановка задачи оперативного прогноза ПЭС
- 2 Входные данные
- 3 Основные этапы моделирования
- 4 Информативность прогнозных параметров
- 5 Результаты прогнозирования
- 6 Выводы

Содержание доклада

- 1 Постановка задачи оперативного прогноза ПЭС
- 2 Входные данные
- 3 Основные этапы моделирования
- 4 Информативность прогнозных параметров
- 5 Результаты прогнозирования
- 6 Выводы

Содержание доклада

- 1 Постановка задачи оперативного прогноза ПЭС
- 2 Входные данные
- 3 Основные этапы моделирования
- 4 Информативность прогнозных параметров
- 5 Результаты прогнозирования
- 6 Выводы

Постановка задачи



Рис.: Использование прогноза ПЭС.

Ионосфера — высокодинамичная среда значительно зависящая от потока солнечного излучения, метеорологических процессов, солнечного ветра.

Оперативный прогноз параметров ионосферы — особенно актуален для систем радиосвязи и радиолокации.

Построение оперативного прогноза ПЭС

Цель

Разработка способа построения эффективной прогнозной модели вертикального полного электронного содержания при помощи технологий машинного обучения.

Задачи

- На основе технологии машинного обучения построить модели прогноза вертикального полного электронного содержания;
- Определить ключевые параметры для построения прогнозных моделей;
- Сравнить полученные модели с простейшими “интуитивными аналогами”;

Входные данные

Входные данные I:

AB ПЭС полученные на основе двухчастотных совместных фазовых и групповых измерений, его первые и вторые производные по времени, индекс солнечной активности F10.7, индексы магнитосферной возмущенности SYM/H, AE

Входные данные II:

экспоненциально взвешенные скользящие средние с различным периодом и ранее полученные данные с различным запаздыванием.

Входные данные

Входные данные I:

AB ПЭС полученные на основе двухчастотных совместных фазовых и групповых измерений, его первые и вторые производные по времени, индекс солнечной активности F10.7, индексы магнитосферной возмущенности SYM/H, AE

Входные данные II:

экспоненциально взвешенные скользящие средние с различным периодом и ранее полученные данные с различным запаздыванием.

Входные данные

Переменная	Описание
I_V	AB ПЭС
G_t	1ая производная по времени AB ПЭС
G_{qt}	2ая производная по времени AB ПЭС
AE	Индекс геомагнитной активности
SYM/H	Индекс магнитосферного возмущения
$F10.7$	Индекс солнечной активности, 10.7 см (2800 MHz)

Основные этапы построения моделей оперативного прогноза

- Формирование данных и предварительная обработка
- Извлечение признаков
- Выбор признаков
- Выбор параметров окончательной модели
- Оценка производительности

Временной ряд АВ ПЭС

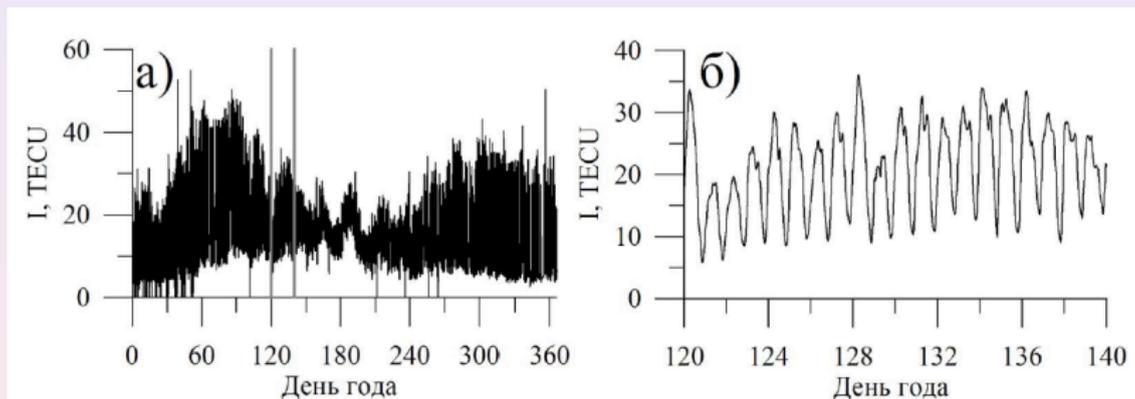
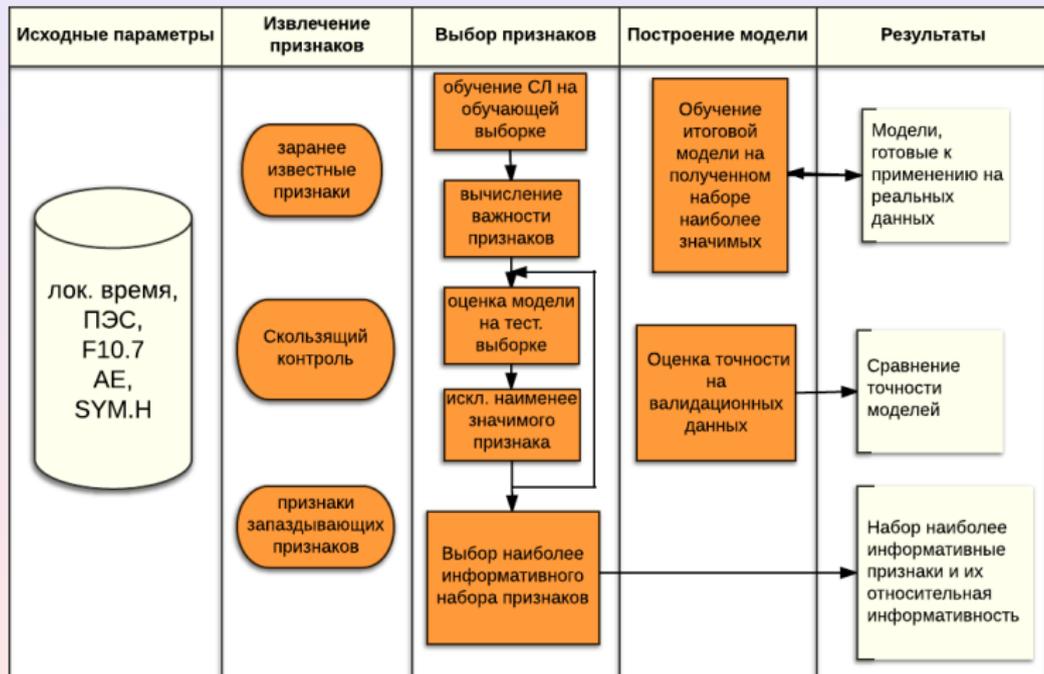


Рис. 1. Исходные данные вертикального ПЭС. На панели б) приведены данные за промежуток времени с 120 по 140 день 2014 г. (период отмечен серыми линиями на панели а)

Схема построения



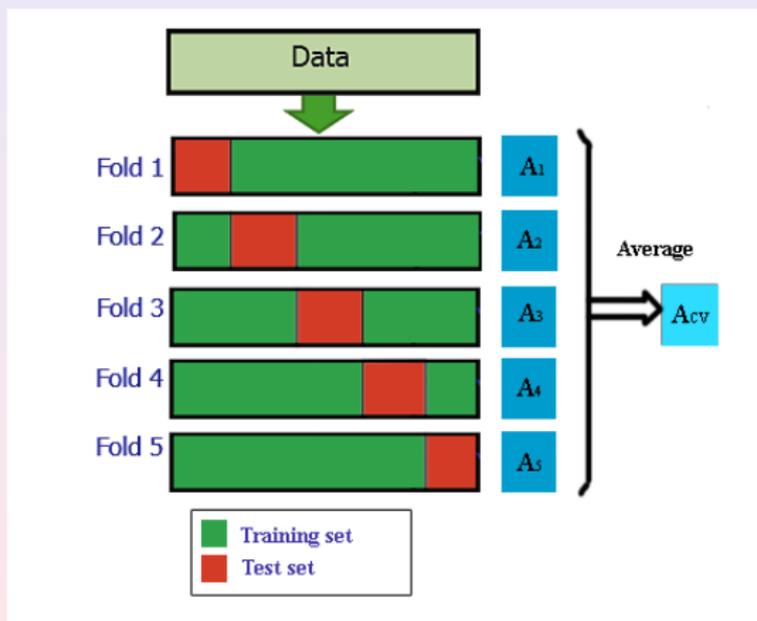
Разбиение данных

67.5% — обучение

22.5% — тестирование

10% — проверка

Скользящий контроль



Средняя ошибка скользящего среднего:
эмпирическое оценивание обобщающей способности алгоритма

Информативность признаков

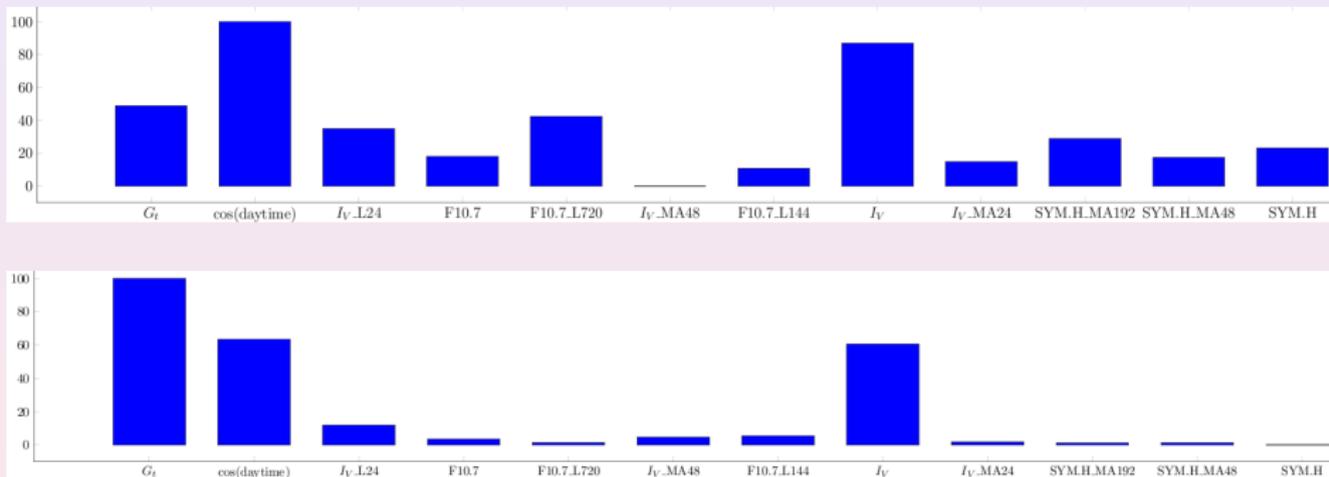


Рис.: Информативность признаков на осн. Random Forest (вверху) and MOB (внизу)

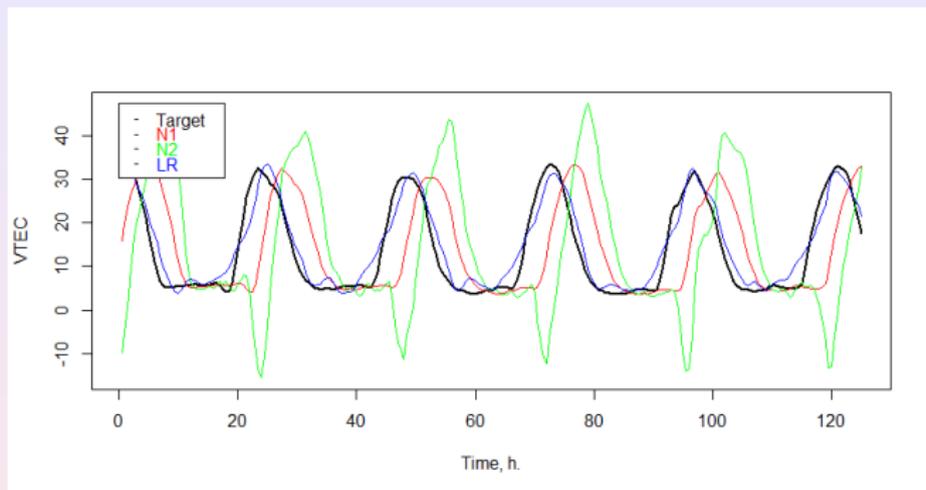


Рис.: 4х часовой прогноз на основе наивных и линейных моделей

N1 – наивная модель: $I(t + \Delta h) = I(t)$

N2 – наивная модель: $I(t + \Delta t) = I(t) + dl/dt \cdot \Delta t$

прогноз на основе RF, GB и SVM

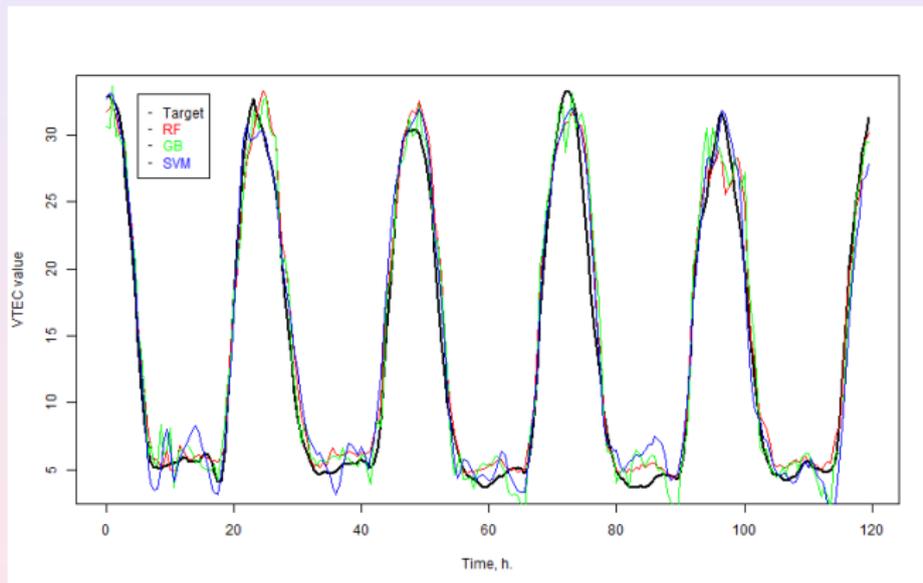


Рис.: 4х часовой прогноз на основе RF, GB и SVM

	СЛ	ГБДР	МОВ	N1	N2	ЛР
СКО	2.26	2.42	2.02	9.14	16.51	3.98
САО	1.35	1.65	1.19	6.74	12.23	2.81

Таблица: Анализ ошибок.

ГБДР – градиентный бустинг деревьев решений

СЛ – случайный лес

МОВ – метод опорных векторов (с радиальным ядром)

N1 – наивная модель: $I(t + \Delta h) = I(t)$

N2 – наивная модель: $I(t + \Delta t) = I(t) + dl/dt \cdot \Delta t$

ЛР – модель на основе многопараметрической линейной регрессии

- Методы машинного обучения позволяют выбрать адекватные параметры для эффективного прогнозирования ПЭС.
- Показано, что ключевые управляющие параметры это — текущая ПЭС, первая производная по времени ПЭС, косинус по локальному времени, $F_{10.7}$ и S_{YM}/H , экспоненциальные скользящие средние ПЭС (с 12, 24, 96 часами), данные о 12-часовом, 2- дневном и 15-дневном отставании $F_{10.7}$.
- Простая линейная регрессионная модель, снабженная соответствующими параметрами, дала неплохой результат ~ 4 TECU.
- Модели машинного обучения, основанные на этих параметрах, позволили вдвое уменьшить СКО (~ 2 TECU)

Спасибо за внимание!