

DOI: 10.25205/978-5-4437-1843-9-34

**ПРЕДСКАЗАНИЕ САЙТОВ ПОСАДКИ ТРАНСКРИПЦИОННЫХ ФАКТОРОВ  
ПО АМИНОКИСЛОТНЫМ ПОСЛЕДОВАТЕЛЬНОСТИЯМ БЕЛКОВ  
С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА**

**PREDICTION OF TRANSCRIPTION FACTOR BINDING SITES BY AMINO ACID SEQUENCES  
OF PROTEINS USING ARTIFICIAL INTELLIGENCE METHODS<sup>\*</sup>**

Н. А. Шелудяков<sup>1</sup>, П. С. Деменков<sup>2</sup>

<sup>1</sup>*Новосибирский государственный университет*

<sup>2</sup>*Институт цитологии и генетики СО РАН, Новосибирск*

N.A. Sheludyakov<sup>1</sup>, P.S. Demenkov<sup>2</sup>

<sup>1</sup>*Novosibirsk State University*

<sup>2</sup>*Institute of Cytology and Genetics SB RAS, Novosibirsk*

 n.sheludyakov@g.nsu.ru

### **Аннотация**

В работе представлен прототип инструмента Prot2Motif, позволяющий по аминокислотной последовательности транскрипционного фактора предсказывать мотивы сайтов посадки на ДНК. Основа модели — рекуррентная нейронная сеть, позволяющая работать как с биологическими последовательностями, так и с их матричными представлениями.

### **Abstract**

A prototype of the Prot2Motif tool is presented in this work. Prot2Motif enables the prediction of DNA binding site motifs based on the amino acid sequence of a transcription factor. The core of the model is a recurrent neural network, which can process both biological sequences and their matrix representations.

В последние десятилетия биоинформатика стала передовой областью научных исследований, которые представляют новые возможности для понимания генетической основы жизни. Одна из задач данной области — поиск сайтов посадки транскрипционных факторов (СПТФ). Транскрипционные факторы (ТФ) — это белки, контролирующие первый этап экспрессии генов. СПТФ — это короткие последовательности нуклеотидов длиной от 5 до 30 нуклеотидов, которые распознаются специальными ДНК-связывающими доменами ТФ. Поиск таких коротких последовательностей позволяет лучше понимать процесс регуляции экспрессии генов на уровне транскрипции.

Существует множество как экспериментальных методик, так и вычислительных инструментов, позволяющих решать данную задачу. Однако инструменты *in silico* могут предсказывать сайты только на основе априорной информации о нуклеотидной последовательности. Поэтому мы разработали прототип инструмента Prot2Motif, который может предсказать сайты посадки исходя из первичной структуры белка. Основа модели — рекуррентная нейронная сеть (RNN), позволяющая генерировать последовательности нуклеотидов.

Наш инструмент включает в себя несколько компонентов. Первым звеном является модель ESM-2 (Evolutionary Scale Modeling), которая переводит последовательность аминокислот в вектора (эмбеддинги). Второе звено — InterProScan, необходимый для поиска ДНК-связывающего домена в белке. Третий компонент — рекуррентная нейронная сеть, позволяющая генерировать частоты встречаемости нуклеотидов в позициях.


В качестве набора данных по мотивам сайтов связывания была взята база данных HOCOMOCO v13. Информация о первичной структуре белков была извлечена из баз данных UniProt и TFclass.

Для оценки качества нейронной сети была выбрана оценка SWscore [1], выражаемая формулой

$$\text{SWscore} = \frac{\sum_{i=1}^m \left( 2 - \sum_{j \in \{A, C, G, T\}} (A_{ij} - B_{ij})^2 \right)}{2m},$$

где  $m$  — длина мотива ( $m = 25$ );  $A_{ij}$  — вероятность нуклеотида  $j$  в позиции  $i$  исходной матрицы;  $B_{ij}$  — вероятность нуклеотида  $j$  в позиции  $i$  сгенерированной матрицы. Оценка SWscore может принимать значения от 0 до 1, где 1 — точное совпадение.

После обучения модели RNN качество предсказания на тестовой выборке составило 0,792, что свидетельствует о возможности модели находить взаимосвязи между структурой мотива сайта посадки и ДНК-связывающего домена белка. На рисунке представлен пример референсного и предсказанного мотива.



*a* — референсное LOGO-представление SPI1.H13CORE.1.S.B;  
*б* — предсказанное LOGO-представление. Белок — Uniprot ID: P17947

В процессе обучения и оценки качества генерации замечено, что модель способна определять консервативность нуклеотидов в позициях — это выражается в корректном выборе наиболее часто встречаемого нуклеотида.

На сегодняшний день проводится оптимизация процесса обучения нейронной сети, что позволит улучшить качество генерации мотивов сайтов связывания.

### Литература

1. Sandelin A., Wasserman W. W. Constrained Binding Site Diversity within Families of Transcription Factors Enhances Pattern Discovery Bioinformatics // Journal of Molecular Biology. 2004. Vol. 338, No. 2. P. 207–215.