

Всероссийский конкурс исследовательских и проектных работ школьников «Высший пилотаж»

«Программный пакет RNAsselem на языке Python для анализа вторичных структур РНК.»

Проект

Направление «Computer Science»

Автор: Казанов Федор Маратович,
учащийся 11класса, ЧУОО СШ “Знайка”, г. Москва

Руководитель проекта: Пономарев Геннадий
Владимирович, научный сотрудник Сколтех,
ИОГен РАН.

2025 г.

Аннотация

Молекулы РНК играют важную роль в различных молекулярных процессах внутри клеток. Вторичная структура молекулы РНК, а именно образование дополнительных водородных связей между малыми молекулами, составляющими молекулу РНК, часто отвечает за выполнение ключевых функций в жизненном цикле клеток и вирусов. Для изучения роли вторичной структуры РНК важно использовать вычислительные инструменты для анализа различных элементов вторичной структуры, включая шпильки, внутренние петли, выпячивания, многоразветвленные петли, стебли и внешние петли. В данном проекте я разработал программный пакет на языке Python для анализа элементов вторичной структуры РНК, который позволяет распознавать основные паттерны вторичной структуры, генерировать описательную статистику для этих структурных элементов и получать их основные характеристики. Разработанный пакет был применен для анализа полных вирусных геномов. Программный пакет, названный RNAsselem, размещен для установки и использования на серверах Github и PyPi.

Актуальность проекта

Основными компонентами клетки являются молекулы ДНК, РНК и белков. Молекула РНК, как и ДНК, является полимером - молекулой, состоящей из однотипных малых молекул, называемых нуклеотидами [1]. Существуют 4 вида нуклеотидов: аденин, тимин, цитозин и гуанин, которые обозначаются соответственно буквами А, Т, С, G. Комплементарными нуклеотидами являются пары аденина с тимином (А – Т) и пары цитозина с гуанином (С – G). Комплементарные нуклеотиды образуют водородные связи [2]. В отличие от двухцепочечной молекулы ДНК, молекула РНК может образовывать различные трехмерные структуры, за счет спаривания нуклеотидов, находящихся в произвольных позициях. Информацию о спаренности нуклеотидов для молекулы РНК называют ее вторичной структурой [3]. Многие типы молекул РНК, такие как рибосомальная РНК и транспортная РНК, имеют определённую вторичную структуру, важную для выполнения их функций [4]. Также вторичная структура РНК имеет большое значение у РНК-вирусов, геномы которых являются длинной молекулой РНК, состоящей из тысяч нуклеотидов [5]. Изучению вторичной структуры РНК посвящается множество исследований, а информацию о вторичной структуре, то есть информацию о спаренности нуклеотидов, принято хранить в файлах специального формата [6]. Вторичная структура может быть логически разбита на некоторые однотипные структурные элементы, такие как стебли, внутренние и внешние петли, шпильки, многоразветвлённые петли, выпячивания (Рис 1) [7]. Последние исследования показывают важность изучения элементов вторичных структур РНК, так как именно отдельные элементы вторичной структуры могут играть значительную функциональную роль. Известными примерами являются RRE элемент (Rev response element), ответственный за селективный экспорт молекул РНК из ядра клетки [8] и FSE элемент (frameshifting stimulation element) вируса SARS-CoV2, выполняющего программный сдвиг рибосомы [9]. Так как роль вторичной структуры РНК у РНК-

вирусов была открыта относительно недавно, на данный момент практически не существует специализированных программных пакетов для анализа элементов вторичной структуры РНК. Поэтому разработка программного пакета, который бы мог выполнять распознавание элементов вторичной структуры на основе входных файлов с информацией о спаренности нуклеотидов, а также выполнять их анализ и подсчитывать описательную статистику, является актуальной задачей.

Литература:

1. Caprara, M. G. & Nilsen, T. W. RNA: Versatility in form and function. *Nat. Struct. Biol.* 7, 831–833 (2000).
2. Strobel, E. J., Watters, K. E., Loughrey, D. & Lucks, J. B. RNA systems biology: Uniting functional discoveries and structural tools to understand global roles of RNAs. *Curr. Opin. Biotechnol.* 39, 182–191 (2016).
3. Ganser, L. R., Kelly, M. L., Herschlag, D. & Al-Hashimi, H. M. The roles of structural dynamics in the cellular functions of RNAs. *Nat. Rev. Mol. Cell Biol.* 20, 474–489 (2019).
4. Spitale, R. C. & Incarnato, D. Probing the dynamic RNA structurome and its functions. *Nat. Rev. Genet.* 24, 178–196 (2023).
5. Boerneke, M. A., Ehrhardt, J. E. & Weeks, K. M. Physical and functional analysis of viral RNA genomes by SHAPE. *Annu. Rev. Virol.* 6, 93–117 (2019).
6. Nawrocki, E. & Eddy, S. RNA Secondary Structures: WUSS Notation, INFERNAL User's Guide. 107–108 <http://eddylib.org/inferna l/Userguide.pdf> (2023).
7. Mathews, D. H. RNA secondary structure analysis using RNAstructure. *Curr. Protoc. Bioinform.* <https://doi.org/10.1002/0471250953.bi1206s46> (2014).
8. Fang, X. et al. XAn unusual topological structure of the HIV-1 rev response element. *Cell* 155, 594 (2013).
9. Hill, C. H. & Brierley, I. Structural and functional insights into viral programmed ribosomal frameshifting. *Annu. Rev. Virol.* 10 (2023).

Цели проекта

Задачей проекта была разработка программного пакета, который выполнял бы следующие задачи:

- Конвертацию вторичной структуры из форматов dot-bracket или CT в формат WUSS, где каждый нуклеотид классифицируется как часть стебля или одного из пяти типов петлевых областей: шпилька (hairpin loop), внутренняя петля (internal loop), выпячивание (bulge loop), многоответвленная петля (multifurcation loop) или внешняя петля (external loop);
- Сбор классифицированных нуклеотидов в отдельные элементы вторичной структуры;

- Получение информации об элементе вторичной структуры для конкретной позиции в последовательности молекулы РНК;
- Генерацию списка структурных элементов определённого типа с указанием их позиций и размеров, включая шпильки, внутренние петли, выпуклости и разветвления;
- Вычисление статистики покрытия генома различными типами структурных элементов;
- Вычисление статистики для структурных элементов определённого типа, включая частоту их встречаемости в геноме, а также расчёт среднего, медианы, стандартного отклонения размеров элементов и их общей длины в геноме.
- Вычисление статистики для спаренных и неспаренных нуклеотидов;

Методы работы

Типы вторичных структур

Существуют различные типы элементов вторичных структур:

- 1) stem (стебель) - структурный элемент, состоящий из двух спаренных участков молекулы РНК, расположенных удаленно друг от друга в пределах цепи РНК. В данной работе стебель, прерывающийся внутренними петлями и выпячиваниями, считается одним элементом, а стебли, прерывающиеся многоразветвленными петлями, считаются разными элементами.
- 2) internal loop (внутренняя петля) - это участок вторичной структуры РНК, который содержит неспаренные нуклеотиды на обеих цепях стебля. Внутренние петли ограничены парами спаренных нуклеотидов, которые замыкают петлю с обеих сторон.
- 3) bulge loop (выпячивание) - это участок вторичной структуры РНК, в котором неспаренные нуклеотиды присутствуют только на одной из цепей стебля. Выпячивание ограничено спаренными нуклеотидами, которые замыкают петлю с обеих сторон.
- 4) multifurcation loop (многоразветвленная петля) - это участок вторичной структуры РНК, представляющий собой области кольца, соединяющего между собой три или более стебля. Стебли не являются частью многоразветвленной петли.
- 5) hairpin loop (петля шпильки) – это участок между двумя комплементарными областями стебля, состоящий из неспаренных нуклеотидов, который образует “шапочку” над стеблем
- 6) external loop (внешняя петля) - участок неспаренных нуклеотидов, не относящийся к другим структурным элементам.

Все эти типы представлены на рисунке 1.




Рисунок 1. Виды элементов вторичной структуры.

Входные данные

Входными данными для программного пакета являлись файлы с информацией о вторичной структуре в трех различных форматах.

- Файл формата dot-bracket. Файл такого формата устроен следующим образом: комплементарные нуклеотиды обозначаются открытыми и закрытыми скобками в соответствующих позициях. Неспаренные нуклеотиды обозначаются точками (Рис 2).

>Example
 AGCCUUGAAGAUGAUGACUTCUGGAGGUCACAGACUCCAUAUACUACAUGUCAGUGUCUCUGUUCAGAGCUGC
 (((...(((((((.....((((...((((.....)))))).....)).((((.....)))))).)))).....))..

Рисунок 2. Файл формата dot-bracket (пример для вторичной структуры, изображенной на рис.1).

- Файл формата connectivity table (CT). В файле данного формата все позиции молекулы РНК пронумерованы, и номер спаренного нуклеотида указывается в отдельном столбце (Рис 3).

75 Example				
1 A 0 2 73 1	16 C 15 17 0 16	31 U 30 32 0 31	46 C 45 47 56 46	61 U 60 62 9 61
2 G 1 3 72 2	17 A 16 18 43 17	32 C 31 33 0 32	47 U 46 48 55 47	62 C 61 63 0 62
3 C 2 4 71 3	18 U 17 19 42 18	33 A 32 34 0 33	48 A 47 49 0 48	63 U 62 64 0 63
4 C 3 5 0 4	19 G 18 20 41 19	34 C 33 35 26 34	49 C 48 50 0 49	64 G 63 65 0 64
5 U 4 6 0 5	20 A 19 21 0 20	35 A 34 36 25 35	50 A 49 51 0 50	65 U 64 66 0 65
6 U 5 7 68 6	21 C 20 22 0 21	36 G 35 37 24 36	51 U 50 52 0 51	66 U 65 67 8 66
7 G 6 8 67 7	22 U 21 23 0 22	37 A 36 38 23 37	52 G 51 53 0 52	67 C 66 68 7 67
8 A 7 9 66 8	23 T 22 24 37 23	38 C 37 39 0 38	53 U 52 54 0 53	68 A 67 69 6 68
9 A 8 10 61 9	24 C 23 25 36 24	39 U 38 40 0 39	54 C 53 55 0 54	69 G 68 70 0 69
10 G 9 11 60 10	25 U 24 26 35 25	40 C 39 41 0 40	55 A 54 56 47 55	70 A 69 71 0 70
11 A 10 12 59 11	26 G 25 27 34 26	41 C 40 42 19 41	56 G 55 57 46 56	71 G 70 72 3 71
12 U 11 13 0 12	27 G 26 28 0 27	42 A 41 43 18 42	57 U 56 58 45 57	72 C 71 73 2 72
13 G 12 14 0 13	28 A 27 29 0 28	43 U 42 44 17 43	58 G 57 59 0 58	73 U 72 74 1 73
14 A 13 15 0 14	29 G 28 30 0 29	44 U 43 45 0 44	59 U 58 60 11 59	74 G 73 75 0 74
15 U 14 16 0 15	30 G 29 31 0 30	45 A 44 46 57 45	60 C 59 61 10 60	75 C 74 76 0 75

Рисунок 3. Файл формата СТ (пример для вторичной структуры, изображенной на рис.1)..

- Файл формата СТ-WUSS. Данный файл аналогичен файлу типа СТ, за исключением дополнительного столбца, в котором приведены аннотации элементов вторичных структур. Нуклеотиды, принадлежащие к структурным элементам hairpin loop, internal loop, bulge loop, multifurcation loop, external loop обозначаются соответственно символами “_”, “-”, “-”, “,”, “:”. Однако stem обозначаются различными символами. Два комплементарных нуклеотида стебля обозначаются различными символами, один из них – открывающей скобкой, другой – закрывающей. Нуклеотиды, принадлежащие стеблю, имеют различные обозначения в зависимости от уровня вложенности: Первый уровень вложенности (внешний) обозначается символом “<” или “>”, второй – символом “(” или “)”, третий - символом “[” или “]”, четвертый - символом “{” или “}”.


75 Example				
1 A 0 2 73 1 (	16 C 15 17 0 16 ,	31 U 30 32 0 31 _	46 C 45 47 56 46 <	61 U 60 62 9 61)
2 G 1 3 72 2 (	17 A 16 18 43 17 <	32 C 31 33 0 32 _	47 U 46 48 55 47 <	62 C 61 63 0 62 -
3 C 2 4 71 3 (	18 U 17 19 42 18 <	33 A 32 34 0 33 _	48 A 47 49 0 48 _	63 U 62 64 0 63 -
4 C 3 5 0 4 -	19 G 18 20 41 19 <	34 C 33 35 26 34 >	49 C 48 50 0 49 _	64 G 63 65 0 64 -
5 U 4 6 0 5 -	20 A 19 21 0 20 -	35 A 34 36 25 35 >	50 A 49 51 0 50 _	65 U 64 66 0 65 -
6 U 5 7 68 6 (	21 C 20 22 0 21 -	36 G 35 37 24 36 >	51 U 50 52 0 51 _	66 U 65 67 8 66)
7 G 6 8 67 7 (	22 U 21 23 0 22 -	37 A 36 38 23 37 >	52 G 51 53 0 52 _	67 C 66 68 7 67)
8 A 7 9 66 8 (	23 T 22 24 37 23 <	38 C 37 39 0 38 -	53 U 52 54 0 53 _	68 A 67 69 6 68)
9 A 8 10 61 9 (	24 C 23 25 36 24 <	39 U 38 40 0 39 -	54 C 53 55 0 54 _	69 G 68 70 0 69 -
10 G 9 11 60 10 (	25 U 24 26 35 25 <	40 C 39 41 0 40 -	55 A 54 56 47 55 >	70 A 69 71 0 70 -
11 A 10 12 59 11 (	26 G 25 27 34 26 <	41 C 40 42 19 41 >	56 G 55 57 46 56 >	71 G 70 72 3 71)
12 U 11 13 0 12 ,	27 G 26 28 0 27 _	42 A 41 43 18 42 >	57 U 56 58 45 57 >	72 C 71 73 2 72)
13 G 12 14 0 13 ,	28 A 27 29 0 28 _	43 U 42 44 17 43 >	58 G 57 59 0 58 ,	73 U 72 74 1 73)
14 A 13 15 0 14 ,	29 G 28 30 0 29 _	44 U 43 45 0 44 ,	59 U 58 60 11 59)	74 G 73 75 0 74 :
15 U 14 16 0 15 ,	30 G 29 31 0 30 _	45 A 44 46 57 45 <	60 C 59 61 10 60)	75 C 74 76 0 75 :

Рисунок 4. Файл формата СТ-WUSS.

Преобразование форматов

Для преобразования файлов вторичных структур РНК и аннотации элементов вторичной структуры были разработаны следующие программные функции:

- Была разработана функция *dotbracket2ct* для преобразования файла формата dot-bracket в файл формата СТ. В качестве входных данных функция принимает два аргумента: *input path* – путь к dot-bracket файлу и *output path* – путь к СТ файлу, в который будет записан результат работы данной функции. Функция устроена следующим образом:
 - 1) Информация из dot-bracket файла переносится в двумерный список, в котором *i*-й список содержит три элемента: номер нуклеотида, символ, обозначающий наличие спаренности (далее – СНС) и буква, обозначающая тип основания нуклеотида (строки пакета 1103 – 1115 на рис. 5).
 - 2) Создается отдельный двумерный список для нуклеотидов, принадлежащих стеблю. У каждого такого нуклеотида СНС – это “(“ или “)” (строки пакета 1117 – 1121, рис. 5).
 - 3) Программа находит в списке стеблей такие два подряд идущих нуклеотида, что СНС первого – это “(“, а СНС второго – это “)”. Такие два нуклеотида спарены между собой, поэтому они добавляются в словарь с парами, после чего удаляются из списка стеблей. Данный шаг выполняется, пока список стеблей не станет пустым (строки пакета 1123 – 1151, рис. 6).
 - 4) Так как теперь известны пары спаренных нуклеотидов, вся информация записывается в СТ файл (строки пакета 1153 – 1170, рис. 6)



```

1095 def dotbracket2ct(input_path, output_path):
1096     """ Converts dot-bracket format file to CT format file
1097
1098     Parameters:
1099         input_path (str): path to the dot-bracket file
1100         output_path (str): path to the output CT file
1101     """
1102
1103     def read_dot_bracket(path):
1104         file = open(path, "r")
1105         name = file.readline()
1106         letters = list(file.readline().strip())
1107         symbols = list(file.readline().strip())
1108         n = len(letters)
1109         dot_bracket_list = []
1110
1111         for i in range(n):
1112             nucleotide = [i + 1, symbols[i], letters[i]]
1113             dot_bracket_list.append(nucleotide)
1114
1115         return [name, dot_bracket_list]
1116
1117     name, dot_bracket_list = read_dot_bracket(input_path)
1118     brackets_list = []
1119     for nucleotide in dot_bracket_list:
1120         if nucleotide[1] in ["(", ")"]:
1121             brackets_list.append(nucleotide)

```

Рисунок 5. Функция *dotbracket2ct*, строки пакета *RNAselem* 1095 – 1121.

```

1123 def delete_pair(brackets_list):
1124
1125     empty = [-2] * 3
1126     pairs = {}
1127     for i in range(len(brackets_list)):
1128
1129         if i == 0:
1130             continue
1131
1132         else:
1133             nucleotide = brackets_list[i]
1134             previous_nucleotide = brackets_list[i - 1]
1135             if nucleotide[1] == ")" and previous_nucleotide[1] == "(":
1136                 l = nucleotide[0]
1137                 r = previous_nucleotide[0]
1138                 pairs[l] = r
1139                 pairs[r] = l
1140                 brackets_list[i] = empty
1141                 brackets_list[i - 1] = empty
1142
1143             while empty in brackets_list:
1144                 brackets_list.remove(empty)
1145
1146     return pairs, brackets_list
1147
1148 connections_dict = {}
1149 while len(brackets_list) != 0:
1150     pairs, brackets_list = delete_pair(brackets_list)
1151     connections_dict.update(pairs)
1152
1153 output_file = open(output_path, "w")
1154 length = len(dot_bracket_list)
1155 output_file.write(f"{length} {name[1:-1]}\n")
1156 n = len(str(length)) + 1
1157 maximum = max(list(connections_dict.keys()))
1158 m = len(str(maximum)) + 1
1159 for i in range(length):
1160     line = f"{i + 1:>{n}}}"
1161     line += " " + dot_bracket_list[i][2]
1162     line += f"{i:>{n}}}"
1163     line += f"{i + 2:>{n}}}"
1164     if i + 1 in connections_dict:
1165         line += f"{connections_dict[i + 1]:>{m}}}"
1166     else:
1167         line += f"{0:>{m}}}"
1168     line += f"{i + 1:>{n}}}"
1169     output_file.write(line + "\n")
1170 output_file.close()

```

Рисунок 6. Функция dotbracket2ct, строки пакета RNASselem 1123 – 1170.

- Была разработана функция для преобразования файла формата CT в файл формата CT-WUSS. Алгоритм определения типов вторичных структур был адаптирован из библиотеки на языке C Easel.

Работа с элементами вторичной структуры РНК

- Предварительно была разработана функция *get_bulge_and_internal_loop_list* (рис. 7), возвращающая список словарей отдельно как для выпячиваний, так и для внутренних петель, где *i*-й словарь содержит информацию об одном структурном элементе, такую как: длина элемента, массив с индексами начала и конца всех интервалов, содержащих данный элемент. В качестве входных данных функция принимает многомерный список с информацией, считанной из CT-WUSS файла. Алгоритм функции устроен следующим образом:

- 1) Алгоритм линейно проходит по каждому нуклеотиду в цепи РНК.
- 2) Находится пара замыкающих нуклеотидов, которые обозначаются открывающимися или закрывающимися скобками, между которыми есть непрерывная последовательность неспаренных нуклеотидов, которые обозначаются символом “-”.
- 3) Находится пара нуклеотидов, которые соответственно спарены с замыкающими нуклеотидами. Если между данной парой также есть непрерывная последовательность неспаренных нуклеотидов, которые обозначаются символом “-”, то данный элемент – это *internal loop*, поэтому вся информация об элементе добавляется в массив для внутренних петель, а иначе – это *bulge loop*, и вся информация добавляется в массив для выпячиваний.

```

320 # private
321 # FedorKazanov-1
322 def get_bulge_and_internal_loop_list(wuss_list):
323     brackets = ["<", ">", "[", "]"]
324     cl_brackets = [">", "<", ">", "<"]
325     loops = ["bulge_loop", "internal_loop", "indefinite_loop"]
326     length = 0
327     interior_loops = []
328     bulge_loops = []
329     used = []
330     left_index = -1
331
332     for i in range(len(wuss_list)):
333         nucleotide = wuss_list[i]
334         previous_nucleotide = wuss_list[i - 1] if i != 0 else 0 * [-3]
335
336         if nucleotide[symbol_column_number] in brackets:
337             if previous_nucleotide[structure_column_number] in loops:
338                 right_index = nucleotide[index_column_number] - 1
339                 left_connection_index = wuss_list[right_index][connection_column_number] - 1
340                 right_connection_index = wuss_list[left_index][connection_column_number] - 1
341                 quantity = right_connection_index - left_connection_index - 1
342                 if quantity > 0:
343                     total_length = length + quantity
344                     intervals = [[left_index + 2, right_index], [left_connection_index + 2, right_connection_index]]
345                     d = get_structure_dict(wuss_list, total_length, intervals)
346                     interior_loops.append(d)
347                     used.append([left_connection_index, right_connection_index])
348                 else:
349                     dictionary = get_structure_dict(wuss_list, length, [[left_index + 2, right_index]])
350                     bulge_loops.append(dictionary)
351                     length = 0
352             elif nucleotide[symbol_column_number] in cl_brackets:
353                 if previous_nucleotide[structure_column_number] in loops:
354                     right_index = nucleotide[index_column_number] - 1
355
356                     if [left_index, right_index] not in used:
357                         dictionary = get_structure_dict(wuss_list, length, [[left_index + 2, right_index]])
358                         bulge_loops.append(dictionary)
359                         length = 0
360             elif nucleotide[structure_column_number] in loops:
361                 if previous_nucleotide[symbol_column_number] in (brackets + cl_brackets):
362                     left_index = previous_nucleotide[index_column_number] - 1
363                     length += 1
364
365     return [interior_loops, bulge_loops]

```

Рисунок 7. Функция *get_bulge_and_internal_loop_list* пакета *RNAselem*.

- Была разработана функция *load_ctwuss* (рис.8), которая загружает файл формата CT-WUSS, возвращая все данные в виде многомерного массива, который в дальнейшем можно подавать в качестве входных данных в большинство других функций. В качестве входных данных функция принимает путь к файлу CT-WUSS. Функция считывает данные из файла и вызывает внутреннюю функцию *get_bulge_and_internal_loop_list*, чтобы различить, к какой структуре относятся нуклеотиды с символом "-". Для нуклеотидов с другими символами не требуется дополнительных действий, чтобы определить, к какой структуре относится данный нуклеотид.

```

372 def load_ctwuss(ctwuss_path):
373     """ Loads CT-modified file with WUSS annotation in additional column.
374
375     Parameters:
376     | ctwuss_path (str): path to the connectivity table (CT) file
377
378     Returns:
379     | genome (List[List]): list of nucleotides with pairing info
380     """
381     if isinstance(ctwuss_path, list):
382         return ctwuss_path
383
384     else:
385         input_file = open(ctwuss_path, "r")
386         input_file.readline()
387         wuss_list = []
388
389         for line in input_file:
390             nucleotide = line.split()
391
392             for i in range(len(nucleotide)):
393                 symbol = nucleotide[i]
394                 if symbol.isdecimal():
395                     nucleotide[i] = int(symbol)
396
397             symbol = nucleotide[-1]
398
399             if symbol == ":":
400                 structure_type = "external_loop"
401             elif symbol == ",":
402                 structure_type = "multifurcation_loop"
403             elif symbol == "_":
404                 structure_type = "hairpin_loop"
405             elif symbol == "-":
406                 structure_type = "indefinite_loop"
407             elif symbol in ["<", "(", "[", "{", ">", ")", "]", "}"]:
408                 structure_type = "stem"
409             else:
410                 structure_type = "pseudoknot"
411
412             nucleotide.append(structure_type)
413             wuss_list.append(nucleotide)
414
415             wuss_list = change_letters(wuss_list, symbol_column_number + 1)
416             bulge_loops = get_bulge_and_internal_loop_list(wuss_list)[1]
417             bulge_indexes = []
418
419             for bulge_loop in bulge_loops:
420                 interval = bulge_loop["intervals"][0]
421                 interval_range = list(range(interval[0], interval[1] + 1))
422                 bulge_indexes += interval_range
423
424             for i in range(len(wuss_list)):
425                 nucleotide = wuss_list[i]
426                 if nucleotide[structure_column_number] == "indefinite_loop":
427                     if i + 1 in bulge_indexes:
428                         wuss_list[i][structure_column_number] = "bulge_loop"
429                     else:
430                         wuss_list[i][structure_column_number] = "internal_loop"
431
432             return wuss_list

```

Рисунок 8. Функция load_ctwuss пакета RNAsselem.

Были разработаны функции, которые возвращают информацию о конкретных типах вторичной структуры в виде массивов, содержащих информацию о длине каждого из элементов вторичной структуры и интервалы с индексами начала и конца каждого из элементов. Такие функции были разработаны для всех типов вторичных структур, включая hairpin loop, internal loop, bulge loop, multifurcation loop, stem, external loop, функции соответственно называются *get_hairpin_loop_list*, *get_internal_loop_list*, *get_bulge_loop_list*, *get_multifurcation_loop_list*, *get_stem_list*, *get_external_loop_list*.

Каждая из этих функций возвращает список словарей, где i-й словарь содержит информацию об одном структурном элементе, такую как: длина элемента, массив с индексами начала и конца всех интервалов, содержащих данный элемент, однако у функции *get_hairpin_loop_list* есть дополнительный параметр – длина стебля, содержащего данную шпильку. В качестве входных данных эти функции принимают CT-WUSS файл или список, полученный с помощью функции *load_ctwuss*.

- Функция *get_hairpin_loop_list* (рис. 9) устроена следующим образом:

- 1) Алгоритм линейно проходит по каждому нуклеотиду в цепи РНК.
- 2) Находится непрерывная последовательность нуклеотидов с символом “_”.
- 3) С помощью функции *get_stem_list* находится длина стебля, содержащего данную шпильку.
- 4) Вся информация записывается в словарь, словарь добавляется в список.

```

694 def get_hairpin_loop_list(ctwuss):
695     """ Returns a list of hairpin loops with a dictionary of their properties.
696
697     Parameters:
698         ctwuss (str/list): path to the CT-modified file or loaded file
699
700     Returns:
701         hairpin_loops (list[dict]): list of the hairpin loop properties, including:
702         - length - element length,
703         - intervals - list of the start/stop positions,
704         - sequences - DNA sequences at the intervals,
705         - stem_length - length of the hairpin's stem.
706     """
707
708     wuss_list = load_ctwuss(ctwuss)
709     stems = get_stem_list(wuss_list)
710     hairpin_loops = []
711     length = 0
712
713     for i in range(len(wuss_list)):
714         nucleotide = wuss_list[i][structure_column_number]
715         if nucleotide == "hairpin_loop":
716             if length == 0:
717                 l_index = i + 1
718                 length += 1
719             else:
720                 if length != 0:
721                     r_index = i
722                     stem_dictionary = get_interval(stems, l_index - 1)
723                     stem_length = stem_dictionary["length"]
724                     d = get_structure_dict(wuss_list, length, [[l_index, r_index]])
725                     d["stem_length"] = stem_length
726                     hairpin_loops.append(d)
727                     length = 0
728
729     return hairpin_loops

```

Рисунок 9. Функция *get_hairpin_loop_list* пакета *RNAselem*.

- Функция `get_internal_loop_list` использует внутреннюю функцию `get_bulge_and_internal_loop_list`, описанную ранее.
- Функция `get_bulge_loop_list` использует внутреннюю функцию `get_bulge_and_internal_loop_list`, описанную ранее.
- Функция `get_multifurcation_loop_list` устроена следующим образом:
 - 1) Из списка, содержащего всю цепь РНК, полученного с помощью функции `load_ctwuss`, поочередно, в зависимости от уровня вложенности, удаляются нуклеотиды, принадлежащие стеблю и нуклеотиды, находящиеся внутри стебля, такие как шпильки, выпячивания и внутренние петли. Первыми удаляются все нуклеотиды стеблей первого (внешнего) уровня вложенности, обозначаемые символом "<" или ">", вторыми – обозначаемые символом "(" или ")", третьими - обозначаемые символом "[" или "]", четвертыми - обозначаемые символом "{" или "}".
 - 2) После удаления каждого из уровней, последовательность подряд идущих нуклеотидов с символом "," являются ровно одной многоразветвленной петлей. Информация о данном элементе записывается в словарь и добавляется в список многоразветвленных петель, после чего все нуклеотиды, принадлежащие данному элементу также удаляются.
 - 3) Алгоритм продолжает работу, пока не будут удалены все уровни.

```

857 def get_multifurcation_loop_list(ctwuss):
858     """ Returns a list of multifurcation loops with a dictionary of their properties.
859
860     Parameters:
861     | ctwuss (str/list): path to the CT-modified file or loaded file
862
863     Returns:
864     | multifurcation_loops (list(dict)): list of the multifurcation loop properties, including:
865     | - length - element length,
866     | - intervals - list of the start/stop positions,
867     | - sequences - DNA sequences at the intervals.
868
869     """
870
871     wuss_list = load_ctwuss(ctwuss)
872     wuss_list_copy = deepcopy(wuss_list)
873
874     Marat Kazanov
875     def find_bracket(bracket, array):
876         for i in range(len(array)):
877             line = array[i]
878             if bracket in line:
879                 return i
880             break
881     else:
882         return -1

```

Рисунок 10. Функция `get_multifurcation_loop_list`. строки пакета `RNAselem` 857 – 881.

```

883 def delete_bracket(array, bracket_index):
884
885     beginning = array[bracket_index]
886     connection_number = beginning[connection_column_number] - 1
887     r = array[bracket_index:]
888     start_index = 1
889     previous_index = -1
890
891     m_nucleotides = []
892
893     for i in range(len(r)):
894         nucleotide = r[i]
895         if nucleotide[structure_column_number] == "multifurcation_loop":
896             m_nucleotides.append(nucleotide)
897
898         if nucleotide[index_column_number] - 1 == connection_number:
899             last_index = bracket_index + i
900             break
901
902     if len(m_nucleotides) == 1:
903         intervals = [[m_nucleotides[0][0], m_nucleotides[0][0]]]
904     else:
905         intervals = []
906         for i in range(len(m_nucleotides)):
907
908             nucleotide = m_nucleotides[i]
909             index = nucleotide[index_column_number] - 1
910
911             if i == 0:
912                 start_index = index
913             else:
914                 if index - previous_index != 1:
915                     intervals.append([start_index + 1, previous_index + 1])
916                     start_index = index
917                 if i == len(m_nucleotides) - 1:
918                     intervals.append([start_index + 1, index + 1])
919
920             previous_index = index
921
922     del array[bracket_index: last_index + 1]
923     multifurcation_loop = get_structure_dict(wuss_list, len(m_nucleotides), intervals)
924
925     return [array, multifurcation_loop]
926
927 multifurcation_loops = []
928 for bracket in ["<", "(", "[", "{"]:
929     while True:
930         bracket_index = find_bracket(bracket, wuss_list_copy)
931         if bracket_index < 0:
932             break
933         wuss_list_copy, multifurcation_loop = delete_bracket(wuss_list_copy, bracket_index)
934         if multifurcation_loop["length"] != 0:
935             multifurcation_loops.append(multifurcation_loop)
936 multifurcation_loops.sort(key=lambda x: x["intervals"][0][0])
937
938 return multifurcation_loops

```

Рисунок 11. Функция `get_multifurcation_loop_list`. строки пакета `RNAsselem` 883 – 938.

- Функция `get_stem_loop_list` устроена следующим образом:
 - 1) Алгоритм линейно проходит по каждому нуклеотиду в цепи РНК.
 - 2) Находятся подряд идущие нуклеотиды, принадлежащие стеблю, с одинаковым символом открывающейся скобки, при этом, если они прерываются выпячиваниями или внутренними петлями, они все равно считаются идущими подряд.
 - 3) Найденному участку находится соответствующий комплементарный участок. Два данных участка составляют полный элемент стебля, информация о котором записывается в словарь и добавляется в список.

```

635 # public
636 def get_stem_list(ctwuss):
637     """ Returns a list of stems with a dictionary of their properties.
638
639     Parameters:
640         ctwuss (str): path to the CT-modified file or loaded file
641
642     Returns:
643         stem_list (list(dict)): list of the with stem properties, including:
644             - length - element length,
645             - intervals - list of the start/stop positions,
646             - sequences - DNA sequences at the intervals.
647
648     """
649
650     wuss_list = load_ctwuss(ctwuss)
651     pairs = [{"(", ")"}, [{"", "}"], [{"<", ">"}, [{"(", ")"}]
652     stem_list = []
653     length = 0
654     left_index = -1
655
656     intervals = []
657     for pair in pairs:
658         bracket = pair[0]
659         cl_bracket = pair[1]
660         for i in range(len(wuss_list)):
661             nucleotide = wuss_list[i]
662
663             if nucleotide[symbol_column_number] == bracket:
664                 previous_nucleotide = wuss_list[i - 1]
665                 next_nucleotide = wuss_list[i + 1] if i != len(wuss_list) - 1 else 8 * [-3]
666                 if length == 0:
667                     end_index = nucleotide[connection_column_number] - 1
668                     length += 1
669                 if previous_nucleotide[symbol_column_number] != bracket:
670                     left_index = nucleotide[index_column_number] - 1
671                 if next_nucleotide[symbol_column_number] != bracket:
672                     intervals.append([left_index + 1, nucleotide[index_column_number]])
673
674             if nucleotide[symbol_column_number] == cl_bracket:
675                 previous_nucleotide = wuss_list[i - 1]
676                 next_nucleotide = wuss_list[i + 1] if i != len(wuss_list) - 1 else 8 * [-3]
677                 length += 1
678                 if previous_nucleotide[symbol_column_number] != cl_bracket:
679                     left_index = nucleotide[index_column_number] - 1
680                 if next_nucleotide[symbol_column_number] != cl_bracket:
681                     intervals.append([left_index + 1, nucleotide[index_column_number]])
682                 if nucleotide[index_column_number] - 1 == end_index:
683                     d = get_structure_dict(wuss_list, length, intervals)
684                     stem_list.append(d)
685                     length = 0
686                     intervals = []
687
688     stem_list.sort(key=lambda x: x["intervals"][0][0])
689
690     return stem_list

```

Рисунок 12. Функция `get stem list` пакета `RNAsselem`.

- Функция `get_external_loop_list` устроена следующим образом:
 - 1) Алгоритм линейно проходит по каждому нуклеотиду в цепи РНК.
 - 2) Находится непрерывная последовательность нуклеотидов с символом “.”, информация о данном элементе записывается в словарь, словарь добавляется в список.

```

555 def get_external_loop_list(ctwuss):
556     """ Returns a list of external loops with a dictionary of their properties.
557
558     Parameters:
559         ctwuss (str/list): path to the CT-modified file or loaded file
560
561     Returns:
562         external_loops (list[dict]): list of the external loop properties, including:
563             - length - element length,
564             - intervals - list of the start/stop positions,
565             - sequences - DNA sequences at the intervals.
566     """
567
568     wuss_list = load_ctwuss(ctwuss)
569     external_loops = []
570     length = 0
571
572     for i in range(len(wuss_list)):
573         nucleotide = wuss_list[i][structure_column_number]
574
575         if nucleotide == "external_loop":
576             if length == 0:
577                 l_index = i + 1
578                 length += 1
579             else:
580                 if length != 0:
581                     r_index = i
582                     d = get_structure_dict(wuss_list, length, [[l_index, r_index]])
583                     external_loops.append(d)
584                     length = 0
585
586         if length != 0:
587             r_index = len(wuss_list)
588             d = get_structure_dict(wuss_list, length, [[l_index, r_index]])
589             external_loops.append(d)
590
591     return external_loops

```

Рисунок 13. Функция `get_external_loop_list` пакета *RNAselem*.

- Была разработана функция `get_structure_type_full`, которая по номеру позиции нуклеотида возвращает данные об элементе вторичной структуры, включающим в себя данный нуклеотид: тип элемента вторичной структуры, длина элемента вторичной структуры, интервалы с индексами начала и конца данного элемента вторичной структуры, строки с фрагментами цепи РНК этого элемента вторичной структуры.

```

1189 def get_structure_type_full(ctwuss, position_index):
1190     """ Returns a type of the structural element at a given 1-based position along with other info.
1191
1192     Parameters:
1193         ctwuss (str/List): path to the CT-modified file or loaded file
1194         position_index (int): genome position
1195
1196     Returns:
1197         element_info (dict): dictionary with the following keys:
1198             - structure_type - type of the secondary structure element,
1199             - length - element length,
1200             - intervals - list of the start/stop positions,
1201             - sequences - DNA sequences at the intervals.
1202     """
1203
1204     wuss_list = load_ctwuss(ctwuss)
1205     structure = wuss_list[position_index - 1][structure_column_number]
1206
1207     if structure == "external_loop":
1208         structures_list = get_external_loop_list(wuss_list)
1209     elif structure == "bulge_loop":
1210         structures_list = get_bulge_loop_list(wuss_list)
1211     elif structure == "internal_loop":
1212         structures_list = get_internal_loop_list(wuss_list)
1213     elif structure == "hairpin_loop":
1214         structures_list = get_hairpin_loop_list(wuss_list)
1215     elif structure == "stem":
1216         structures_list = get_stem_list(wuss_list)
1217     elif structure == "multifurcation_loop":
1218         structures_list = get_multifurcation_loop_list(wuss_list)
1219
1220     structure_dictionary = get_interval(structures_list, position_index)
1221
1222     sequences = get_sequences(wuss_list, structure_dictionary["intervals"], position_index)
1223
1224     final_dict = {"structure_type": structure, "length": structure_dictionary["length"],
1225                  "intervals": structure_dictionary["intervals"], "sequences": sequences}
1226     if structure == "hairpin_loop":
1227         final_dict["stem_length"] = structure_dictionary["stem_length"]
1228
1229     return final_dict

```

Рисунок 14. Функция `get_structure_type_full` пакета `RNAsselem`.

Описательная статистика элементов вторичной структуры

- Была разработана внутренняя функция *statistics*, которая для конкретного типа элементов вторичной структуры возвращает различные статистические данные, такие как количество элементов конкретного типа вторичной структуры, средняя длина, медиана длины, стандартное отклонение длины элемента конкретного типа вторичной структуры и общая длина всех элементов конкретного типа вторичной структуры.

```

521 def statistics(results_list):
522     length_list = []
523     for element in results_list:
524         length = element["length"]
525         length_list.append(length)
526
527     count = len(length_list)
528     length_list.sort()
529     mean_length = sum(length_list) / count
530
531     if count % 2 == 0:
532         r = count // 2
533         l = r - 1
534         median_length = (length_list[r] + length_list[l]) / 2
535     else:
536         i = (count + 1) // 2
537         median_length = length_list[i]
538
539     sq = []
540     for n in length_list:
541         m = n - mean_length
542         sq.append(m ** 2)
543     d = sum(sq) / count
544     std_length = sqrt(d)
545
546     total_length = sum(length_list)
547
548     values = [count, round(mean_length, 2), round(median_length, 2), round(std_length, 2), total_length]
549     keys = ["count", "mean_length", "median_length", "std_length", "total_length"]
550     stat_dict = dict(zip(keys, values))
551     return stat_dict

```

Рисунок 15. Функция *statistics* пакета *RNAsselem*.

- Для удобства применения программного пакета были добавлены отдельные функции для вычисления описательной статистики для каждого из структурных элементов определённого типа. Функции называются *get_stem_stat*, *get_external_loop_stat*, *get_internal_loop_stat*, *get_bulge_loop_stat*, *get_multifurcation_loop_stat*, *get_hairpin_loop_stat*. В качестве входных данных каждая из функций принимает CT-WUSS файл или массив с информацией из CT-WUSS файла. Каждая из этих функций сначала вызывает функцию для получения списка с конкретными элементами данной вторичной структуры, затем передает полученный список в функцию *statistics*, после чего возвращает список со статистическими данными.
- Была разработана функция *save_stat* для сохранения всех статистических данных для всех типов элементов вторичной структуры РНК вируса в качестве текстового файла.

```

1056 def save_stat(ctwuss_path, output_path, is_append=False):
1057     """ Saves statistics for all types of structural elements to file.
1058
1059     Calculates and saves statistics on hairpin loops, internal loops, bulges, multifurcation loops and external loops to a specified output file.
1060
1061     Parameters:
1062         ctwuss_path (str): path to the CT-modified file or loaded file
1063         output_path (str): path to the output file
1064         is_append (bool): append output to existing file or create a new file
1065     """
1066
1067     lines = ["External_loops", "Hairpin_loops", "Internal_loops", "Bulge_loops", "Multifurcation_loops", "Stems"]
1068     stat = [get_external_loop_stat(ctwuss_path), get_hairpin_loop_stat(ctwuss_path),
1069            get_internal_loop_stat(ctwuss_path),
1070            get_bulge_loop_stat(ctwuss_path), get_multifurcation_loop_stat(ctwuss_path), get_stem_stat(ctwuss_path)]
1071
1072     if isfile(output_path) and not is_append:
1073         print("This file is already exist. Delete this file and try again.")
1074         return -1
1075
1076     output_file = open(output_path, "a")
1077     if is_append:
1078         output_file.write("\n" * 2)
1079
1080     line1 = basename(ctwuss_path)
1081     output_file.write(line1 + "\n")
1082     line2 = "\tCount\tMean_length\tMedian_length\tStd_length\tTotal_length\n"
1083     output_file.write(line2)
1084
1085     for i in range(6):
1086         line = lines[i] + "\t"
1087         stat_values = list(stat[i].values())
1088         for j in range(5):
1089             stat_values[j] = str(stat_values[j])
1090         line += "\t".join(stat_values) + '\n'
1091     output_file.write(line)
1092     return 0

```

Рисунок 16. Функция `save_stat` пакета `RNAselem`.

- Были написаны функции `get_paired` и `get_unpaired` для подсчета количества спаренных и неспаренных нуклеотидов в РНК.

```

487 def get_unpaired(ctwuss):
488     """ Returns the number of unpaired nucleotides in genome.
489
490     Parameters:
491         ctwuss (str/list): path to the CT-modified file or loaded file
492
493     Returns:
494         unpaired_cnt (int): number of unpaired nucleotides
495     """
496
497     wuss_list = load_ctwuss(ctwuss)
498     connection_indexes = get_columns(wuss_list, connection_column_number)
499     unpaired_cnt = connection_indexes.count(0)
500     return unpaired_cnt

```

Рисунок 17. Функция `get_unpaired` пакета `RNAselem`.

```


504 def get_paired(ctwuss):
505     """ Returns the number of paired nucleotides in genome.
506
507     Parameters:
508     |   ctwuss (str/list): path to the CT-modified file or loaded file
509
510     Returns:
511     |   paired_cnt (int): number of paired nucleotides
512     """
513
514     total_length = get_total_length(ctwuss)
515     unpaired = get_unpaired(ctwuss)
516     paired_cnt = total_length - unpaired
517     return paired_cnt

```

Рисунок 18. Функция `get_paired` пакета `RNAselem`.

Результаты

Разработанный пакет для анализа вторичной структуры РНК `RNAselem` был помещен в репозиторий сервера Github по адресу <https://github.com/KazanovLab/RNAselem> для предоставления возможности общего доступа к пакету, ведения версий пакета и протоколирования ошибок, замечаний и предложений (Рис 19).



The screenshot shows the GitHub repository for `RNAselem`. The README section describes the package as a Python tool for analyzing RNA secondary structure elements in viral genomes. It lists features such as converting dot-bracket or CT format to WUSS format, assembling nucleotides into complete secondary structure elements, and calculating statistics on pairing and unpairing of nucleotides. The installation instructions are provided for both git and pip. A diagram of an RNA secondary structure is also visible, showing various elements like hairpin loops, bulges, and internal loops.

Рисунок 19. Пакет `RNAselem` на сервере Github.

Для возможности свободной установки для всех пользователей, пакет был размещен в репозитории Python Package index (PyPi), предназначенном для хранения и распространения пакетов на языке Python (Рис 20).




Рисунок 20. Пакет RNAselem в репозитории PyPi.

Разработанный мной пакет был применен сотрудниками центра молекулярной и клеточной биологии Сколковского университета науки и технологий для анализа вируса Денге, трех подвидов вируса гепатита С и четырех штаммов коронавируса SARS-CoV-2. По результатам анализа сотрудниками была опубликована статья в международном рецензированном научном журнале Scientific Reports (Рис 21).

[nature](#) > [scientific reports](#) > [articles](#) > [article](#)

Article | [Open access](#) | Published: 19 November 2024

Analysis of the abundance and diversity of RNA secondary structure elements in RNA viruses using the RNAsselem Python package

[Fedor M. Kazanov](#), [Evgenii V. Matveev](#), [Gennady V. Ponomarev](#), [Dmitry N. Ivankov](#) & [Marat D. Kazanov](#) 

[Scientific Reports](#) **14**, Article number: 28587 (2024) | [Cite this article](#)

1311 Accesses | **2** Altmetric | [Metrics](#)

Abstract

Recent advancements in experimental and computational methods for RNA secondary structure detection have revealed the crucial role of RNA structural elements in diverse molecular processes within living cells. It has been demonstrated that the secondary structure of the entire viral genome is often responsible for performing crucial functions in the viral life cycle and also influences virus evolution. To investigate the role of viral RNA secondary structure, alongside experimental techniques, the use of bioinformatics tools is important for analyzing various secondary structure patterns, including hairpin loops, internal loops, multifurcations, external loops, bulges, stems, and pseudoknots. Here, we have introduced a Python package for analyzing RNA secondary structure elements in viral genomes, which includes the recognition of common secondary structure patterns, the generation of descriptive statistics for these structural elements, and the provision of their basic properties. We applied the developed package to analyze the secondary structures of complete viral

Download PDF 

Sections

Figures

References

[Abstract](#)

[Introduction](#)

[Methods](#)

[Results](#)

[Discussion](#)

[Data availability](#)

[References](#)

[Acknowledgements](#)

[Author information](#)

[Ethics declarations](#)

[Additional information](#)

[Electronic supplementary material](#)

[Rights and permissions](#)

[About this article](#)

Advertisement

Рисунок 21. Страница публикации научного проекта с применением пакета RNAsselem в научном журнале Scientific reports.