

Министерство науки и высшего образования Российской Федерации
НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ
ТОМСКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ (НИ ТГУ)

Институт биологии, экологии, почвоведения, сельского и лесного хозяйства
(Биологический институт)

УТВЕРЖДЕНО:
Директор
Д. С. Воробьев

Оценочные материалы по дисциплине

Прикладная биоинформатика

по направлению подготовки

06.04.01 Биология

Направленность (профиль) подготовки:

**Физиология, биохимия, биотехнология и биоинформатика растений и
микроорганизмов**

Форма обучения
Очная

Квалификация
Магистр

Год приема
2024

СОГЛАСОВАНО:
Руководитель ОП
О.В. Карначук

Председатель УМК
А.Л. Борисенко

Томск – 2025

1. Компетенции и индикаторы их достижения, проверяемые данными оценочными материалами

Целью освоения дисциплины является формирование следующих компетенций:

ОПК-6 Способен творчески применять и модифицировать современные компьютерные технологии, работать с профессиональными базами данных, профессионально оформлять и представлять результаты новых разработок;

ОПК-8 Способен использовать современную исследовательскую аппаратуру и вычислительную технику для решения инновационных задач в профессиональной деятельности.

ПК-2 Способен проводить основные этапы полевых и лабораторных исследований в соответствии с профилем (направленностью) магистерской программы.

Результатами освоения дисциплины являются следующие индикаторы достижения компетенций:

ИОПК-6.1 Описывает разнообразие, пути и перспективы применения компьютерных технологий в современной биологии

ИОПК-6.2 Использует компьютерные технологии и профессиональные базы данных при планировании профессиональной деятельности, обосновывает их выбор

ИОПК-8.2 Применяет современную исследовательскую аппаратуру и вычислительную технику при решении стандартных и инновационных задач в профессиональной деятельности

ИПК-2.3 Получает научно значимые результаты при использовании полевых и лабораторных методов исследования биологических объектов, в том числе применяя современную аппаратуру и оборудование

ИПК-2.4 Описывает, обобщает и делает выводы на основе результатов исследования, в том числе с помощью современных компьютерных технологий

2. Оценочные материалы текущего контроля и критерии оценивания

Элементы текущего контроля:

- тесты;
- контрольная работа;

Тест (ИОПК-6.1, ИОПК-6.2, ИОПК-8.2, ИПК-2.3, ИПК-2.4)

1. Какая из перечисленных структур данных в языке R предназначена для хранения данных с различными типами элементов (гетерогенных данных)?

- а) Вектор
- б) Матрица
- в) Список (`list`)
- г) Массив (`array`)

2. Что из перечисленного является ключевой характеристикой функционального программирования, реализуемого в R с помощью таких функций как `'lapply()'` или `'purrr::map()'`?

- а) Изменение состояния программы через побочные эффекты
- б) Использование циклов `'for'` для итераций
- в) Применение функций к элементам коллекций без изменения исходных данных
- г) Обязательное использование объектно-ориентированного подхода

3. Для чего в R преимущественно используется механизм нестандартной оценки (NSE), например, в пакете `'dplyr'`?

- а) Для ускорения вычислений

- б) Для написания более читаемого и лаконичного кода, оперирующего именами переменных без кавычек
 - в) Для компиляции кода в машинные инструкции
 - г) Для обработки исключений и ошибок
4. Что является основной целью метапрограммирования в контексте языка R?
- а) Написание программ, которые анализируют и модифицируют другие программы или самих себя
 - б) Исключительно создание графиков и визуализаций
 - в) Проведение статистического тестирования гипотез
 - г) Нормализация данных секвенирования
5. Какой из этапов анализа данных RNA-seq следует сразу после контроля качества сырых последовательностей (fastq-файлов) и перед поиском дифференциально экспрессированных генов?
- а) Визуализация результатов в публикационном качестве
 - б) Выравнивание ридов на референсный геном или транскриптом
 - в) ПЦР-валидация полученных результатов
 - г) Нормализация данных для устранения технических вариаций
6. Какой тип биочипов используется преимущественно для анализа метилирования ДНК?
- а) SNP-чипы
 - б) МикроРНК-чипы
 - в) Чипы для сравнительной геномной гибридизации (aCGH)
 - г) Чипы на метилирование
7. Что из перечисленного является типичной задачей анализа данных полногеномного секвенирования (NGS), которая НЕ выполняется при анализе данных RNA-seq?
- а) Контроль качества сырых ридов
 - б) Выравнивание на референсный геном
 - в) Поиск однонуклеотидных полиморфизмов
 - г) Поиск дифференциально экспрессированных генов

Ключи: 1 в), 2 в), 3 б), 4 а), 5 г), 6 г), 7 г).

Критерии оценивания: тест считается пройденным, если обучающий ответил правильно как минимум на половину вопросов.

Контрольная работа (ИОПК-6.1, ИОПК-6.2, ИОПК-8.2, ИПК-2.3, ИПК-2.4)

Контрольная работа состоит из 2 теоретических вопросов и 1 задачи.

Перечень теоретических вопросов:

1. Опишите основные структуры данных в языке R. В каких ситуациях целесообразно применение каждой из них?
2. Дайте определение функциональному программированию. Какие функционалы реализованы в R и для решения каких задач они применяются?
3. Что такое нестандартная оценка (non-standard evaluation, NSE) в R? Приведите примеры её использования в популярных пакетах для анализа данных.

4. Раскройте понятие «метапрограммирование» в контексте языка R. Какой пакет является современным стандартом для метапрограммирования в R и какие задачи он решает?
5. Опишите ключевые этапы анализа данных RNA-seq, начиная от сырых последовательностей (fastq) и заканчивая списком дифференциально экспрессированных генов.
6. В чём заключаются основные различия в подходах к контролю качества и нормализации данных для микрочипов и для данных высокопроизводительного секвенирования (NGS)?
7. Какие основные типы генетических вариантов выявляются при анализе данных полногеномного NGS? Опишите краткий алгоритм их детекции.

Задачи:

Задача 1. Исследователь получил данные RNA-seq в виде 6 файлов в формате FASTQ (по 3 на условие). Опишите последовательность действий и назовите конкретные программные пакеты или инструменты, которые необходимо использовать для преобразования этих сырых-данных в таблицу counts (матрицу экспрессии) для последующего статистического анализа.

Задача 2. Дан вектор значений экспрессии генов:

<code>expression_values <- c(5.1, 12.8, 0.05, 8.4, 0.01, 15.2, 0.5)</code>

Напишите код на R, который использует функциональный подход для преобразования всех значений меньше 1.0 в NA, а все остальные значения логарифмирует по основанию 2.

Задача 3. В таблице `metadata` содержится информация об образцах: колонка `sample_id` и колонка `treatment` (Control или Treated). Таблица `counts_matrix` содержит counts для генов (строки - гены, столбцы - `sample_id`). Напишите фрагмент кода на R с использованием принципов нестандартной оценки, чтобы отфильтровать образцы только из группы Treated и выбрать для них гены со средним значением экспрессии > 10.

Задача 4. Используя средства в R, напишите функцию `create_summary`, которая принимает на вход `data.frame` и вектор имён числовых колонок, а возвращает новый `data.frame` с рассчитанными для указанных колонок средним значением и стандартным отклонением. Функция должна использовать `tidy evaluation`.

Задача 5. После выравнивания ридов RNA-seq на референсный геном и получения таблицы counts с помощью `featureCounts`, среднее количество прочитанных ридов на ген составило 500. Общее количество детектированных генов – 15000. Один из генов имеет `count = 25`. Является ли это значение аномально низким? Обоснуйте свой ответ, предложив метод нормализации, который позволит корректно сравнивать экспрессию этого гена между образцами.

Задача 6. Для анализа данных метилирования ДНК, полученных с помощью Illumina Infinium MethylationEPIC микромассивов, были получены сырые сигналы (`intensity values`). Опишите шаги биоинформатической обработки этих данных для получения бета-значений метилирования (`beta-values`) для каждого исследуемого CpG-сайта.

Задача 7. При анализе данных полногеномного секвенирования (WGS) для поиска однонуклеотидных вариантов (SNV) был использован следующий пайплайн: `BWA-MEM -> Samtools -> GATK HaplotypeCaller`. Объясните, какую функцию выполняет каждый из этих инструментов в данном пайплайне. Почему для детекции SNV недостаточно просто посмотреть позицию в выравнивании (BAM-файле)?

Ответы к задачам:

Задача 1. Ответ: 1. Контроль качества ридов (FastQC, MultiQC). 2. Выравнивание на референсный геном/транскриптом (STAR, HISAT2). 3. Сортировка и преобразование

выравниваний (samtools). 4. Подсчет ридов, наложившихся на гены (featureCounts, HTSeq). 5. Формирование таблицы counts.

Задача 2. Код ответа:

```
library(purrr)
expression_values <- c(5.1, 12.8, 0.05, 8.4, 0.01, 15.2, 0.5)
result <- map_dbl(expression_values, ~ ifelse(.x < 1.0, NA, log2(.x)))
```

Задача 3. Код ответа или его вариации:

```
library(dplyr)
filtered_data <- metadata %>%
  filter(treatment == "Treated") %>%
  left_join(counts_matrix, by = "sample_id") %>%
  summarise(across(where(is.numeric), ~ mean(.x) > 10))
```

Задача 4. Код ответа или его вариации:

```
library(rlang)
library(dplyr)
create_summary <- function(df, cols) {
  cols <- syms(cols)
  df %>%
    summarise(across(!!!cols, list(mean = mean, sd = sd),
      na.rm = TRUE, .names = "{.col}_{.fn}"))
}
```

Задача 5. Ответ: Да, значение 25 является низким на фоне среднего 500. Для корректного сравнения необходима нормализация, учитывающая разную глубину секвенирования и состав библиотек (например, TPM, FPKM/RPKM или методы, используемые в DESeq2/edgeR).

Задача 6. Ответ: 1. Нормализация фонового сигнала. 2. Коррекция типа Infinium-Assay (I/II). 3. Расчет степени метилирования как $\beta = M / (M + U + \alpha)$, где M и U – метилированный и неметилированный сигналы, α – константа для стабилизации дисперсии.

Задача 7. Ответ: BWA-MEM производит выравнивание ридов на референс. Samtools производит сортировку и индексацию BAM-файлов. GATK HaplotypeCaller выполняет коррекцию ошибок выравнивания, повторное выравнивание вокруг indels и статистическое определение вариантов, что критично для минимизации ложноположительных результатов.

Критерии оценивания контрольной работы

Результаты контрольной работы определяются оценками «отлично», «хорошо», «удовлетворительно», «неудовлетворительно».

Оценка «отлично» выставляется, если:

- Даны полные, развернутые и правильные ответы на 2 теоретических вопроса.
- Верно решена задача, приведены необходимые расчеты и аргументированные пояснения.
- Продемонстрировано глубокое понимание принципов работы методов и умение их применять для анализа.

Оценка «хорошо» выставляется, если:

- Даны в основном правильные ответы на 2 теоретических вопроса, возможны незначительные неточности или неполнота.
- Верно решена задача, в решениях допущены незначительные ошибки в расчетах или формулировках, но общий принцип решения верен.

Оценка «удовлетворительно» выставляется, если:

- Теоретические вопросы раскрыты поверхностно, с существенными неточностями, дан правильный ответ только на 1 вопрос.
- В решении задач допущены существенные ошибки, но продемонстрировано частичное понимание подхода.

Оценка «неудовлетворительно» выставляется, если:

- Ответы на теоретические вопросы неверны или отсутствуют.
- Задача не решена или решение фундаментально неверно.
- Демонстрировано полное непонимание принципов работы методов.

3. Оценочные материалы итогового контроля (промежуточной аттестации) и критерии оценивания

Зачетный билет содержит 3 теоретических вопроса.

Перечень вопросов:

1. Дайте характеристику основным структурам данных в R. В каких биоинформатических задачах целесообразно применение каждой из них?
2. Что такое объектно-ориентированное программирование (ООП) в R? Опишите системы S3 и S4, приведите примеры их использования в биоинформатических пакетах.
3. Опишите процесс отладки (debugging) кода в R. Какие инструменты и функции доступны для поиска и исправления ошибок?
4. Раскройте понятия «лексическое окружение» (environment) и «область видимости» (scope) в R. Как они влияют на выполнение функций?
5. Что такое функциональное программирование? Перечислите и охарактеризуйте основные функционалы и их применение для обработки биологических данных.
6. Дайте определение «функциональным операторам». Что такое мемоизация? Как она реализуется в R и для каких задач полезна в биоинформатике?
7. Что такое нестандартная оценка (non-standard evaluation, NSE) в R? Объясните на примерах из пакета `dplyr`, в чем ее преимущества и недостатки.
8. Для чего применяются регулярные выражения? Приведите примеры использования функций `grep()`, `grep1()`, `sub()`, `gsub()` для обработки биологических данных.
9. Что такое предметно-ориентированный язык (DSL)? Приведите примеры DSL, реализованных в пакетах для R.
10. Дайте определение метапрограммированию. Какую роль в метапрограммировании в R играют `quoting (` `)`, `unquoting (`!!`, `!!!`)` и квазиквотации (quasiquote)?
11. Опишите современный подход к метапрограммированию в R с использованием пакета `rlang`. Для решения каких задач в разработке пакетов и анализе данных он применяется?
12. Что такое интерфейс внешних языков (Foreign Language Interface) в R? Опишите основные методы использования функций языков C/C++ из R.
13. Какие методы профилирования кода в R Вам известны? Опишите, как использовать функции `Rprof()` и `profvis` для поиска «узких мест» (bottlenecks) в программе.
14. Опишите основные принципы и инструменты для обработки больших данных в R. В чем их преимущества перед базовыми структурами данных?
15. Опишите полный биоинформатический пайплайн анализа данных RNA-seq: от raw-reads (FASTQ) до получения списка дифференциально экспрессированных генов. Назовите ключевые инструменты для каждого этапа.
16. В чем заключаются основные задачи этапа контроля качества (QC) данных RNA-seq? Какие программы используются для QC сырых ридов (FASTQ) и выравниваний (BAM)?

17. Что такое нормализация данных RNA-seq? Сравните основные методы нормализации (TPM, FPKM/RPKM, методы, используемые в DESeq2 и edgeR).

18. Опишите принцип работы ДНК-микрочипов. В чем заключаются ключевые различия в подготовке и анализе данных для ген-экспрессионных чипов и чипов на метилирование ДНК?

19. Опишите этапы первичного анализа данных микрочипов: контроль качества, нормализация, отбор проб для дальнейшего анализа.

20. Опишите основные типы данных высокопроизводительного секвенирования (NGS) второго поколения (Illumina) и третьего поколения (PacBio, Oxford Nanopore). В чем их ключевые различия и области применения?

21. Опишите биоинформатический пайплайн для идентификации однонуклеотидных полиморфизмов и коротких indels по данным полногеномного секвенирования (WGS). Назовите ключевые этапы и используемые программы.

Критерии оценивания:

Результаты зачет определяются оценками «зачтено» или «не зачтено».

Оценка «зачтено» если дан как минимум два правильных ответа на теоретические вопросы с незначительными неточности, в ином случае выставляется оценка «не зачтено».

4. Оценочные материалы для проверки остаточных знаний (сформированности компетенций)

Тест

1. Способность описывать разнообразие, пути и перспективы применения компьютерных технологий в современной биологии проявляется в понимании: (ИОПК-6.1)

- а) только возможностей текстовых редакторов для написания научных статей.
- б) только принципов работы ПЦР-амплификаторов.
- в) возможностей языков программирования (R, Python) и стандартных биоинформатических пайплайнов для анализа OMIC-данных.
- г) исключительно устройства центрифуг и хроматографов.

2. Для обоснования выбора компьютерной технологии и профессиональных баз данных при планировании профессиональной деятельности необходимо: (ИОПК-6.2)

- а) использовать только первый попавшийся в поисковике онлайн-сервис.
- б) руководствоваться исключительно стоимостью лицензии на программное обеспечение.
- в) проанализировать тип решаемой биологической задачи, формат и объем данных, преимущества и недостатки доступных инструментов.
- г) доверить выбор коллеге.

3. Применение современной исследовательской аппаратуры и вычислительной техники для решения стандартных задач в профессиональной деятельности включает: (ИОПК-8.2)

- а) ручной подсчет клеток под микроскопом без использования цифровых камер и ПО для анализа изображений.
- б) использование штангенциркуля для измерения размера пробирки.
- в) запуск стандартного пайплайна для анализа RNA-seq на высокопроизводительном вычислительном кластере.
- г) запись результатов эксперимента исключительно в бумажный лабораторный журнал.

4. Получение научно значимых результатов с использованием лабораторных методов исследования биологических объектов подразумевает: (ИПК-2.3)

- а) проведение эксперимента без соблюдения протокола и контроля качества.

- б) использование только устаревшего оборудования, так как его настройки всем известны.
- в) корректное применение современного лабораторного оборудования (например, секвенатора) для генерации данных, пригодных для последующего биоинформатического анализа.
- г) подгонку данных под желаемый результат.

5. Описание, обобщение и формулировка выводов на основе результатов исследования с помощью современных компьютерных технологий — это: (ИПК-2.4)

- а) устный пересказ результатов руководителю.
- б) создание таблиц в Excel, построение графиков средствами ggplot2 в R и использование статистических тестов для подтверждения гипотез.
- в) удаление сырых данных после получения результата.
- г) запись ключевых цифр на салфетке.

Ключи: 1 в), 2 в), 3 в), 4 в), 5 б)

Теоретические вопросы:

1. Опишите роль языка программирования R и его специфических пакетов (bioconductor) в современной биологии. Приведите примеры задач, которые решаются с их помощью. (ИОПК-6.1)

Ответ должен содержать определение R как языка для статистической обработки и визуализации данных; упоминание областей применения (геномика, транскриптомика, протеомика); примеры конкретных задач (анализ RNA-seq, GWAS, визуализация путей/pathways).

2. По каким критериям выбирается программное обеспечение и базы данных для планирования биоинформатического исследования? (ИОПК-6.2)

Ответ должен содержать критерии выбора (репутация и актуальность базы данных, тип предоставляемой информации, удобство программного интерфейса (API), совместимость с выбранными методами анализа, наличие технической поддержки).

3. Как современная вычислительная техника (вычислительные кластеры, облачные сервисы) решает проблему обработки больших объемов данных, получаемых с помощью исследовательской аппаратуры (секвенаторы, масс-спектрометры)? (ИОПК-8.2)

Ответ должен содержать определение понятия «большие данные» в биологии; описание принципов высокопроизводительных вычислений (параллельная обработка, распределенные вычисления); преимущества использования кластеров и облачных платформ (масштабируемость, воспроизводимость).

4. Опишите, как применение современной лабораторной аппаратуры и последующий биоинформатический анализ позволяют получить научно значимый результат на примере исследования дифференциальной экспрессии генов. (ИПК-2.3)

Ответ должен содержать описание ключевых этапов работы от подготовки библиотек до секвенирования; переход к этапу биоинформатики: контроль качества, выравнивание, нормализация, статистический анализ; формулировку результата в виде списка значимых генов.

5. Какие современные компьютерные технологии используются на заключительном этапе исследования для описания, обобщения и визуализации полученных биологических результатов? (ИПК-2.4)

Ответ должен содержать использование скриптовых языков (R/Python) для воспроизводимого анализа; создание информативных графиков (тепловые карты, volcano plots); использование инструментов для аннотации генов (GO-термины, pathways); применение систем контроля версий (Git) для управления кодом и результатами.

Информация о разработчиках

Слепцов Алексей Анатольевич, кандидат медицинских наук, кафедра физиологии растений, биотехнологии и биоинформатики Биологического института Национального исследовательского Томского государственного университета, доцент.