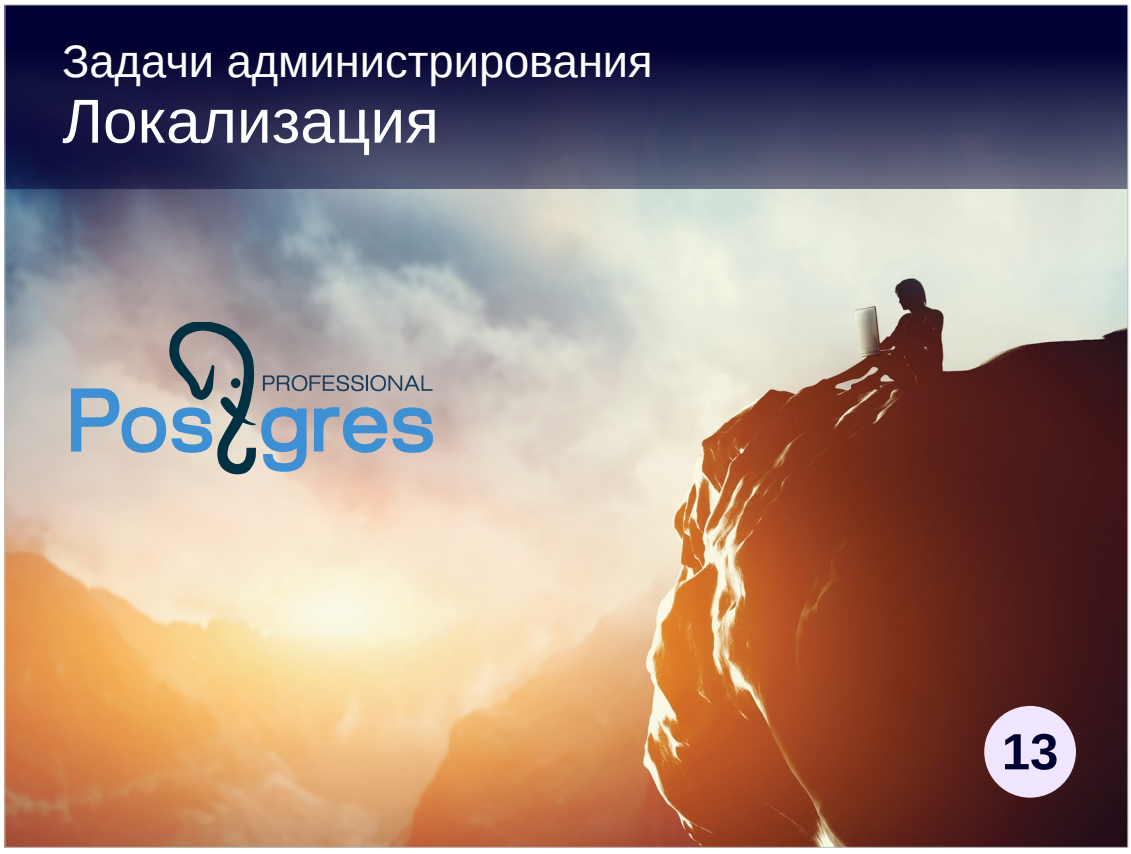



Авторы: Егор Рогов, Павел Лузанов, Илья Баштанов



**Обратная связь**
Отзывы, замечания и предложения направляйте по адресу:
edu@postgrespro.ru

# Темы

Назначение локализации

Локали и категории

Работа с датами, числами, денежными единицами

Настройка сервера и клиента

Настройка сообщений сервера и клиентских утилит

Правила сортировки

# Назначение

Поддержка кодировок

- выбор кодировки символов для различных языков
- перекодировка символов между клиентом и сервером

Функционал, зависящий от локализации

- сортировка и сравнение символов
- функции upper, lower, initcap
- поиск по шаблону
- функции to_char с датами, числами, денежными единицами
- язык сообщений сервера и утилит



Возможности локализации в PostgreSQL позволяют хранить текст в различных кодировках. Для русского языка поддерживаются все основные кодировки символов, включая UTF8, WIN1251, KOI8R, ISO_8859_5.

Клиентское приложение может работать в кодировке, отличной от кодировки сервера. В таком случае настраивается преобразование символов между клиентом и сервером.

Кроме поддержки различных кодировок локализация влияет на работу следующего функционала сервера:

- сортировка символов, например в предложениях ORDER BY или в операциях сравнения (>, <);
- преобразование букв в верхний и нижний регистр в функциях upper, lower, initcap;
- поиск по шаблону в регулярных выражениях, операторах LIKE, SIMILAR TO, включая поиск без учета регистра символов;
- форматирование дат, чисел и денежных единиц в функциях to_char;
- выбор языка сообщений сервера и утилит.

https://postgrespro.ru/docs/postgresql/13/locale

# Локали и категории

## Локали

определяют язык, территорию и кодировку символов, например `ru_RU.UTF8`

установлены в операционной системе

## Категории локали

| | |
|---|---|
| lc_ctype | классификация символов |
| lc_collate | правила сортировки символов |
| lc_messages | язык сообщений |
| lc_monetary | формат денежных единиц |
| lc_numeric | формат чисел |
| lc_time | формат даты и времени |



PostgreSQL использует возможности локализации, предоставляемые операционной системой. Поэтому в ОС следует предварительно настроить локали, которые потребуются для работы СУБД.

Обычно локали в ОС задаются в формате «`язык_территория.кодировка`». Например, `ru_RU.UTF8` определяет локаль с русским языком (ru), на котором говорят в России (RU), и кодировкой UTF8. В Windows используются развернутые имена: `Russian_Russia.1251`.

Язык и территория определяют такие национальные особенности, как порядок символов, формат даты, разделитель десятичных разрядов и т. п.

Иногда бывает необходимо комбинировать поведение некоторых функций из разных локалей. Например, вместе с правилами сортировки русского языка использовать английские сообщения сервера. PostgreSQL поддерживает раздельную установку категорий локали через одноименные параметры конфигурации.

### Локали и категории

В операционной системе сервера должны быть установлены локали с поддержкой русского языка:

```
student$ locale -a | grep ru
```

```
ru_RU.koi8r
ru_RU.utf8
russian
```

Параметры локализации сеанса ОС определяются переменными окружения:

```
student$ locale
```

```
LANG=en_US.UTF-8
LANGUAGE=en_US
LC_CTYPE="en_US.UTF-8"
LC_NUMERIC=ru_RU.UTF-8
LC_TIME=ru_RU.UTF-8
LC_COLLATE="en_US.UTF-8"
LC_MONETARY=ru_RU.UTF-8
LC_MESSAGES=en_US.UTF8
LC_PAPER=ru_RU.UTF-8
LC_NAME=ru_RU.UTF-8
LC_ADDRESS=ru_RU.UTF-8
LC_TELEPHONE=ru_RU.UTF-8
LC_MEASUREMENT=ru_RU.UTF-8
LC_IDENTIFICATION=ru_RU.UTF-8
LC_ALL=
```

Помимо переменных, соответствующих категориям локали, здесь также присутствуют переменные, имеющие особое значение:

- LC_ALL — если установлена, то используется для всех категорий локали, даже если они заданы;
- LANG — используется для тех категорий локали, для которых значение не задано;
- LANGUAGE — если установлена, то используется вместо LC_MESSAGES (об этом далее).

---

При установке PostgreSQL из пакета в виртуальной машине курса для инициализации кластера main были использованы параметры сеанса ОС. Если нужно задать другие значения, можно использовать ключ --locale (эквивалентен LANG), а также ключи для каждой категории, например так:

```
student$ pg_createcluster 13 new_cluster --locale=ru_RU.UTF-8 --lc-messages=en_US.UTF-8
```

Шесть параметров PostgreSQL соответствуют одноименным категориям локали. Видно, что их меньше чем в ОС:

```
=> SELECT name, setting, context, sourcefile
FROM pg_settings
WHERE name LIKE 'lc%';
```

```
    name     |   setting   |  context  |               sourcefile
-------------+-------------+-----------+----------------------------------------
 lc_collate  | en_US.UTF-8 | internal  |
 lc_ctype    | en_US.UTF-8 | internal  |
 lc_messages | en_US.UTF-8 | superuser | /etc/postgresql/13/main/postgresql.conf
 lc_monetary | ru_RU.UTF-8 | user      | /etc/postgresql/13/main/postgresql.conf
 lc_numeric  | ru_RU.UTF-8 | user      | /etc/postgresql/13/main/postgresql.conf
 lc_time     | ru_RU.UTF-8 | user      | /etc/postgresql/13/main/postgresql.conf
(6 rows)
```

Параметры lc_ctype и lc_collate задаются при инициализации кластера и изменить их невозможно. Значения остальных четырех параметров записываются в конфигурационный файл. При этом параметры lc_monetary, lc_numeric и lc_time может изменить любой пользователь (context=user), а lc_messages — только суперпользователь.

---

Каждый обслуживающий процесс при запуске сбрасывает значение LC_ALL и устанавливает переменные окружения ОС для категорий локали в соответствии с конфигурационными параметрами "lc%".

При изменении параметра по ходу сеанса обслуживающий процесс устанавливает это же значение для соответствующей переменной окружения.

Стандартные базы postgres, template0 и template1 используют параметры lc_collate и lc_ctype кластера, кодировка баз также определяется этими параметрами.

Новые базы данных по умолчанию копируют параметры используемого шаблона:

```
=> CREATE DATABASE admin_localization_utf8;
```

```
CREATE DATABASE
```

```
=> \list admin_localization_utf8|template1
```

```
                                    List of databases
          Name           |  Owner   | Encoding |   Collate   |    Ctype    |   Access privileges
-------------------------+----------+----------+-------------+-------------+-----------------------
 admin_localization_utf8 | student  | UTF8     | en_US.UTF-8 | en_US.UTF-8 |
 template1               | postgres | UTF8     | en_US.UTF-8 | en_US.UTF-8 | =c/postgres          +
                         |          |          |             |             | postgres=CTc/postgres
(2 rows)
```

---

## Даты и LC_TIME

Параметр конфигурации, отвечающий за соответствующую категорию локали:

```
=> SET lc_time = 'ru_RU.UTF8';
```

```
SET
```

Для использования названий месяцев и дней недели на русском языке в форматной маске функции to_char используется префикс TM:

```
=> SELECT to_char(current_date, 'TMDay, DD TMmonth YYYY');
```

```
         to_char
-------------------------
 Пятница, 16 декабря 2022
(1 row)
```

То же самое для американского английского:

```
=> SET lc_time = 'en_US.UTF8';
```

```
SET
```

```
=> SELECT to_char(current_date, 'TMDay, DD TMMonth YYYY');
```

```
         to_char
-------------------------
 Friday, 16 December 2022
(1 row)
```

Функции to_date/to_char позволяют в явном виде указать формат даты и времени при вводе/выводе значений. На неявное преобразование даты в текст и наоборот влияет параметр datestyle. Вот несколько примеров:

```
=> SET datestyle = 'Postgres'; SELECT current_setting('datestyle') AS datestyle, now();
```

```
SET
   datestyle   |                 now
---------------+-----------------------------------
 Postgres, DMY | Fri 16 Dec 19:48:50.059555 2022 MSK
(1 row)
```

```
=> SET datestyle = 'SQL, DMY'; SELECT current_setting('datestyle') AS datestyle, now();
```

```
SET
 datestyle |              now
-----------+-------------------------------
 SQL, DMY  | 16/12/2022 19:48:50.119249 MSK
(1 row)
```

```
=> SET datestyle = 'SQL, MDY'; SELECT current_setting('datestyle') AS datestyle, now();
```

```
SET
 datestyle |              now
-----------+-------------------------------
 SQL, MDY  | 12/16/2022 19:48:50.171597 MSK
(1 row)
```

```
=> RESET datestyle; SELECT current_setting('datestyle') AS datestyle, now();
```

```
RESET
 datestyle |              now
-----------+-------------------------------
 ISO, DMY  | 2022-12-16 19:48:50.226626+03
(1 row)
```

---

### Числа и LC_NUMERIC

Параметр конфигурации, отвечающий за соответствующую категорию локали:

```
=> SET lc_numeric = 'ru_RU.UTF8';
```

```
SET
```

Разделители групп разрядов (G), а также целой и дробной части (D), принятые в России:

```
=> SELECT to_char('12345'::numeric, '999G999D00');
```

```
   to_char
-------------
   12 345,00
(1 row)
```

То же для США:

```
=> SET lc_numeric = 'en_US.UTF8';
```

```
SET
```

```
=> SELECT to_char('12345'::numeric, '999G999D00');
```

```
   to_char
-------------
   12,345.00
(1 row)
```

---

### Денежные единицы и LC_MONETARY

Параметр конфигурации, отвечающий за соответствующую категорию локали:

```
=> SET lc_monetary = 'ru_RU.UTF8';
```

```
SET
```

Денежный тип данных MONEY добавляет к сумме код валюты:

```
=> SELECT '12345'::money;
```

```
    money
-------------
 12 345,00 ₽
(1 row)
```

Но нужно учитывать, что в таблице с таким типом можно хранить только одну валюту, и та будет меняться вместе с LC_MONETARY:

```
=> SET lc_monetary = 'en_US.UTF8';
```

```
SET
```

```
=> SELECT '12345'::money;
```

```
   money
------------
 $12,345.00
(1 row)
```

# Настройка сервера

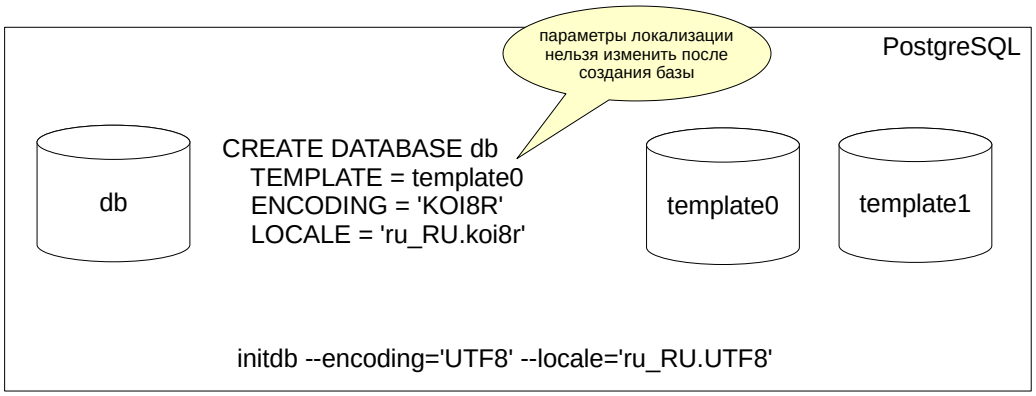


LC_COLLATE = en_US.UTF8
LC_CTYPE = en_US.UTF8



Установка локали выполняется при инициализации кластера баз данных. Утилита initdb использует локаль из окружения ОС, либо локаль можно указать явно через соответствующие параметры.

При создании новой базы данных из шаблона template0 можно указать параметры локализации, отличные от тех, что использовались при инициализации кластера баз данных.

К основным параметрам локализации базы данных относятся: кодировка символов (encoding), а также категории локали lc_ctype и lc_collate, которые удобно задавать одним параметром (ключом) locale, потому что их значения обычно совпадают.

На эти категории локали накладываются ограничения:

- кодировки символов у locale (lc_ctype и lc_collate) должны совпадать с кодировкой базы данных.
- после создания базы данных locale (lc_ctype и lc_collate) изменить нельзя.

Второе ограничение объясняется тем, что изменение правил сортировки и классификации символов может нарушить работу существующих индексов. Кроме того, может измениться поведение операций сравнения текстовых строк в ограничениях CHECK и табличных триггерах, что сделает уже сохраненные данные некорректными.

Именно поэтому, если нужно создать базу с отличающимися параметрами локализации, необходимо использовать шаблон template0, в котором гарантированно нет никаких данных.

# Настройка клиента

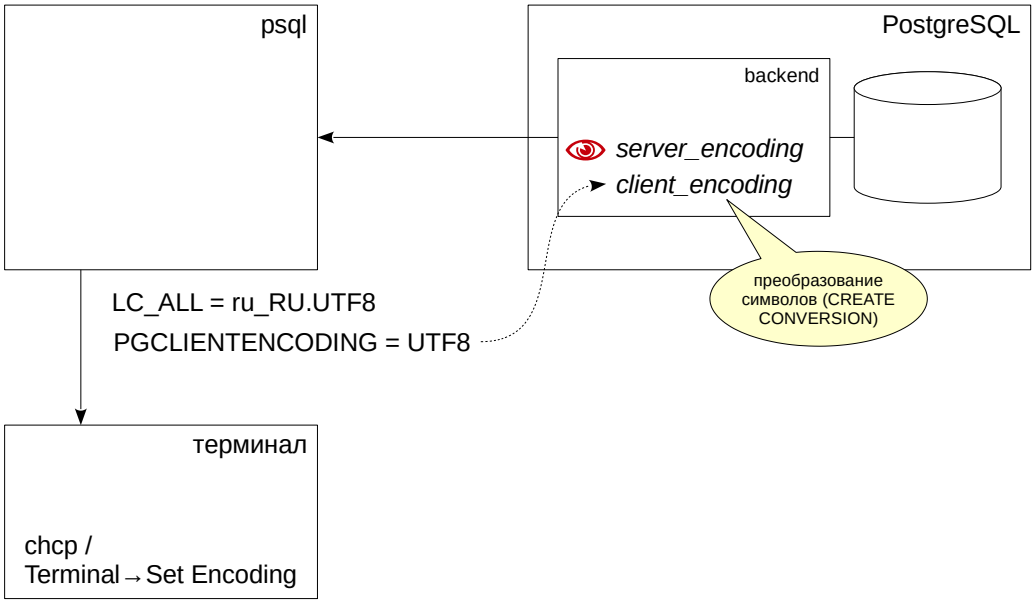


7

Для настройки локализации клиентского приложения нужно сделать следующее.

- Проверить, что настройки сервера корректны. Как минимум, что используется правильная кодировка БД (неизменяемый параметр *server_encoding* покажет кодировку, заданную при создании БД).
- Проверить, что в клиентской ОС установлены нужные локали, и настроить категории локали (переменные среды LC_*) в сеансе ОС.
- Настроить кодировку, с которой работает приложение, и проверить настройки устройства вывода.
  Например, psql в Windows обычно использует кодировку Win-1251, поэтому в терминале (cmd.exe) необходимо выполнить команду `chcp 1251` и установить шрифт true type (например, Lucida Console).
- После подключения к БД проверить параметр *client_encoding*. Этот параметр отвечает за перекодировку символов между клиентом и сервером. При необходимости установить в значение кодировки приложения. Значение *client_encoding* можно задать и в переменной среды PGCLIENTENCODING.

Обслуживающий процесс автоматически перекодирует символы из кодировки БД (server_encoding) в кодировку клиента (client_encoding). Для большинства кодировок в PostgreSQL преднастроены необходимые процедуры преобразования символов: они находятся в таблице системного каталога pg_conversion. Возможно создание дополнительных пользовательских процедур (CREATE CONVERSION).

### Работа клиента и сервера в разных кодировках

Создадим базу данных с кодировкой KOI8R, а клиент по-прежнему будет использовать UTF8. Чтобы база данных успешно создалась, нужно учесть следующее:

- в ОС должна быть установлена локаль с нужной кодировкой символов;
- нужно использовать шаблон template0: это пустая БД, индексы в которой гарантированно не пострадают в результате изменения кодировки.

Значения LC_COLLATE и LC_CTYPE, как правило, должны быть согласованы, поэтому обычно их устанавливают вместе одним параметром LOCALE:

```
=> CREATE DATABASE admin_localization_koi8r
  ENCODING = 'koi8r'
  LOCALE = 'ru_RU.koi8r'
  TEMPLATE = template0;
```

```
CREATE DATABASE
```

```
=> \l admin_localization_koi8r
```

```
                                      List of databases
           Name           |  Owner  | Encoding |   Collate   |    Ctype    | Access privileges
--------------------------+---------+----------+-------------+-------------+-------------------
 admin_localization_koi8r | student | KOI8R    | ru_RU.koi8r | ru_RU.koi8r |
(1 row)
```

Подключимся к admin_localization_koi8r и убедимся, что работает перекодировка символов.

```
=> \c admin_localization_koi8r
```

```
You are now connected to database "admin_localization_koi8r" as user "student".
```

Кодировки клиента и сервера:

```
=> SELECT name, setting, context
FROM pg_settings
WHERE name LIKE '%encoding';
```

```
      name       | setting | context
-----------------+---------+----------
 client_encoding | KOI8R   | user
 server_encoding | KOI8R   | internal
(2 rows)
```

Значение параметра client_encoding устанавливает клиент, в данном случае psql. В интерактивном режиме значение устанавливается по кодировке клиента (переменной LC_CTYPE в ОС). Но при запуске из скрипта, как сейчас в демонстрации, параметр устанавливается в значение кодировки базы данных.

Явно зададим такое же значение, как и у клиентской локали:

```
=> \! locale | grep LC_CTYPE
```

```
LC_CTYPE="en_US.UTF-8"
```

```
=> SET client_encoding = 'UTF-8';
```

```
SET
```

Теперь символы будут правильно конвертироваться из UTF8 в KOI8R и обратно:

```
=> CREATE TABLE tab AS SELECT 'Привет, мир!'::text AS col;
```

```
SELECT 1
```

```
=> SELECT * FROM tab;
```

```
     col
--------------
 Привет, мир!
(1 row)
```

Список доступных перекодировок для koi8:

```
=> \dcS *koi8*
```

```
                              List of conversions
   Schema   |          Name           |    Source     |  Destination  | Default?
------------+-------------------------+---------------+---------------+----------
 pg_catalog | iso_8859_5_to_koi8_r    | ISO_8859_5    | KOI8R         | yes
 pg_catalog | koi8_r_to_iso_8859_5    | KOI8R         | ISO_8859_5    | yes
 pg_catalog | koi8_r_to_mic           | KOI8R         | MULE_INTERNAL | yes
 pg_catalog | koi8_r_to_utf8          | KOI8R         | UTF8          | yes
 pg_catalog | koi8_r_to_windows_1251 | KOI8R         | WIN1251       | yes
 pg_catalog | koi8_r_to_windows_866   | KOI8R         | WIN866        | yes
 pg_catalog | koi8_u_to_utf8          | KOI8U         | UTF8          | yes
 pg_catalog | mic_to_koi8_r           | MULE_INTERNAL | KOI8R         | yes
 pg_catalog | utf8_to_koi8_r          | UTF8          | KOI8R         | yes
 pg_catalog | utf8_to_koi8_u          | UTF8          | KOI8U         | yes
 pg_catalog | windows_1251_to_koi8_r | WIN1251       | KOI8R         | yes
 pg_catalog | windows_866_to_koi8_r   | WIN866        | KOI8R         | yes
(12 rows)


=> \c admin_localization_utf8

You are now connected to database "admin_localization_utf8" as user "student".
```

# Сообщения сервера

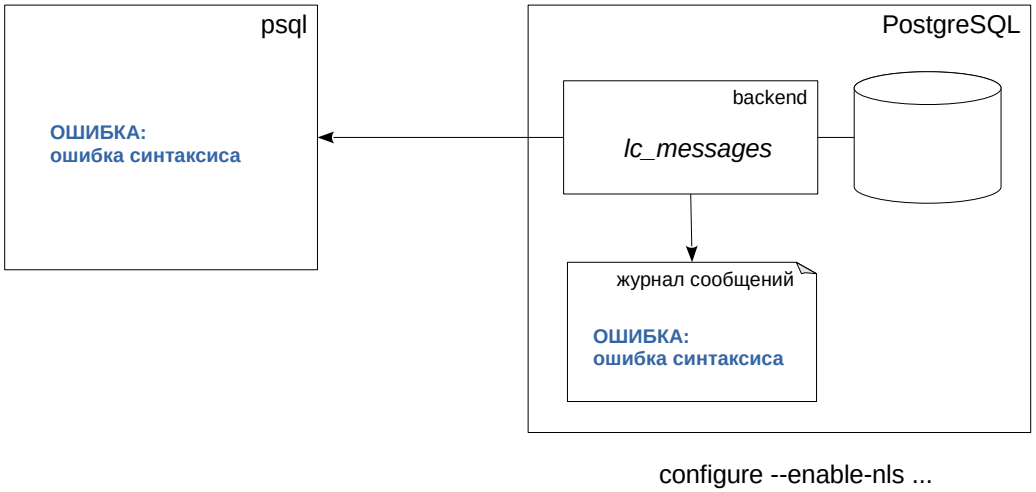


configure --enable-nls ...



Сообщения сервера (и утилит) PostgreSQL переведены на несколько языков. В том числе и на русский.

Для того чтобы сообщения сервера выводились на русском языке, нужно, чтобы сервер PostgreSQL был собран с поддержкой национальных языков (`configure --enable-nls`).

Параметр конфигурации *lc_messages* управляет языком сообщений сервера.

Сообщения сервера не только отправляются клиенту, но и записываются в журнал сервера. При выборе языка, отличного от английского, следует убедиться, что инструменты работы с журналом сервера понимают этот язык. Например pgBadger может работать только с английскими сообщениями.

Подробнее о переводе сообщений сервера для переводчиков и разработчиков: https://postgrespro.ru/docs/postgresql/13/nls

# Сообщения утилит

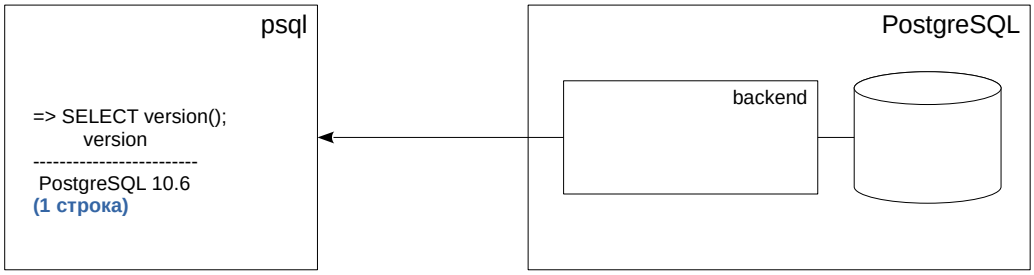


configure --enable-nls ...
export LC_MESSAGES=ru



Утилиты PostgreSQL (psql, pg_dump и пр.) также поддерживают национальные языки.

Для того, чтобы сообщения утилит выводились на языке, отличном от английского, нужно, чтобы клиент PostgreSQL был собран с поддержкой NLS. Язык вывода устанавливается на клиенте переменной среды LC_MESSAGES (параметр сервера *lc_messages* влияет только на сообщения самого сервера, но не клиента).

Большинство ОС (включая Windows) используют следующий порядок просмотра переменных среды для языка сообщений: LANGUAGE, LC_ALL, LC_MESSAGES, LANG.

### Сообщения сервера и клиента

Сообщения сервера можно выводить на разных языках. Предварительно нужно убедиться, что PostgreSQL собран с поддержкой национальных языков:

```
=> SELECT unnest(regexp_match(setting,'--enable-nls')) config
FROM pg_config()
WHERE name = 'CONFIGURE';

    config
--------------
 --enable-nls
(1 row)
```

Список доступных языков и файлы сообщений здесь:

```
=> SELECT setting
FROM pg_config()
WHERE name = 'LOCALEDIR';

      setting
------------------
 /usr/share/locale
(1 row)
```

```
postgres$ ls -C /usr/share/locale
```

```
aa          ca@valencia  fa_IR  is            mhr    pl        ti
ab          ce           ff     it            mi     pms       tig
ace         ch           fi     it_CARES      mjw    ps        tk
ach         chr          fil    iu            mk     pt        tl
af          ckb          fo     ja            ml     pt_BR     tr
ak          co           fr     jam           mn     ro        trv
am          crh          fr_CA  jv            mnw    ru        tt
an          cs           frp    ka            mo     rw        tt@iqtelif
ar          csb          fur    kab           mr     sa        tzm
arn         cv           fy     ki            ms     sc        ug
ary         cy           ga     kk            mt     sd        uk
as          da           gd     kl            my     sdh       ur
ast         de           gez    km            na     se        ur_PK
ay          de_CH        gl     kmr           nah    shn       uz
az          dv           gn     kn            nb     si        uz@Latn
ba          dz           gu     ko            nb_NO  sk        ve
bar         ee           gv     kok           nds    sl        vec
be          el           ha     ku            ne     so        vi
be@latin    en           haw    kv            nl     son       wa
bem         en_AU        he     kw            nn     sq        wae
be@tarask   en@boldquot  hi     ky            nso    sr        wal
bg          en_CA        hr     la            nv     sr@latin  wo
bi          en_GB        ht     lb            ny     sr@Latn   xh
bn          en@quot      hu     lg            oc     sv        yo
bn_BD       en@shaw      hy     ln            om     sw        zh_CN
bn_IN       eo           hy_AM  lo            or     szl       zh_Hans
bo          es           hye    locale.alias  os     ta        zh_Hant
br          et           ia     lt            pa     ta_LK     zh_HK
bs          eu           id     lv            pam    te        zh_LATN@pinyin
byn         fa           ie     mai           pap    tg        zh_TW
ca          fa_AF        io     mg            pi     th        zu
```

Для записи в журнал будем использовать ошибочную команду:

```
=> select1;

ERROR:  syntax error at or near "select1"
LINE 1: select1;
        ^
```

```
postgres$ tail -n 2 /var/log/postgresql/postgresql-13-main.log

2022-12-16 19:48:51.766 MSK [106427] student@admin_localization_utf8 ERROR:  syntax error at or near "select1" at character 1
2022-12-16 19:48:51.766 MSK [106427] student@admin_localization_utf8 STATEMENT:  select1;
```

В журнал сервера записывается такое же сообщение об ошибке и сама ошибочная команда.

---

Для вывода сообщений на русском языке надо изменить параметр lc_messages.

```
=> SET lc_messages TO 'ru_RU.UTF8';

SET

=> select1;

ОШИБКА:  ошибка синтаксиса (примерное положение: "select1")
LINE 1: select1;
        ^
```

```
postgres$ tail -n 2 /var/log/postgresql/postgresql-13-main.log

2022-12-16 19:48:51.905 MSK [106427] student@admin_localization_utf8 ОШИБКА:  ошибка синтаксиса (примерное положение: "select1") (символ 1)
2022-12-16 19:48:51.905 MSK [106427] student@admin_localization_utf8 ОПЕРАТОР:  select1;
```

Теперь сообщение выводится клиенту и в журнал на русском языке.

---

Посмотрим на сообщения, которые выводит клиент psql. Они остались на английском языке:

```
=> \dt
```

```
Did not find any relations.
```

Язык сообщений клиента, собранного с поддержкой национальных языков, определяется переменными ОС LC_MESSAGES и LANGUAGE, причем LANGUAGE имеет приоритет:

```
=> \! echo $LC_MESSAGES
```

```
en_US.UTF8
```

```
=> \! echo $LANGUAGE
```

```
en_US
```

Для полной русификации установим русский язык и для сообщений psql.

```
=> \q
```

```
student$ export LANGUAGE=ru_RU
```

```
student$ psql -d admin_localization_utf8
```

```
=> \dt
```

```
Отношения не найдены.
```

```
=> SET lc_messages TO 'ru_RU.UTF8';
```

```
SET
```

Теперь все сообщения выводятся на русском языке.

# Правила сортировки

Объекты базы данных

- разные правила сортировки в одной БД
- начальное наполнение при создании БД
- указываются для столбцов таблиц и в выражениях

Провайдеры

- libc
- ICU

Специальные правила сортировки

- «C» и «POSIX»



Чтобы в одной базе данных можно было по-разному сортировать и сравнивать текстовые данные, в PostgreSQL существуют специальные объекты — правила сортировки (collation). Они позволяют использовать порядок сортировки, отличный от установленного по умолчанию для базы данных.

При создании правила сортировки указываются внешняя библиотека, реализующая сортировку (провайдер), и классификация символов. Начиная с PostgreSQL 10 можно выбирать между библиотеками ICU и libc; до этого всегда использовалась libc.

Начальный список объектов — правил сортировки — формируется при инициализации кластера. Для всех имеющихся в ОС локалей в базу данных загружаются правила сортировки. В дальнейшем при добавлении локалей в ОС можно дозагрузить правила.

Правила сортировки можно использовать при создании текстовых столбцов таблиц, при определении доменов и просто в выражениях, где сортируются или сравниваются текстовые строки.

Специальные правила сортировки «C» и «POSIX» работают одинаково и создаются для всех кодировок сервера. Для этих правил буквами будут считаться только латинские символы от A до Z, все остальные знаки будут сортироваться в соответствии со своими кодами в данной кодировке.

Посмотреть имеющиеся правила сортировки можно в таблице системного каталога pg_collation.

https://postgrespro.ru/docs/postgresql/13/collation

# Провайдер libc

Порядок символов

- зависит от реализации в операционной системе

Изменения в библиотеке

- отслеживается номер версии

Использование

- по умолчанию для базы данных или кластера
- явное указание при определении столбцов и в выражениях



Правила сортировки провайдера libc в базе данных работают точно так же, как и в операционной системе. Однако библиотека libc может быть реализована по-разному в разных операционных системах. Как следствие, сортировка для одних и тех же локалей может отличаться в зависимости от ОС сервера базы данных. Если приложение должно поддерживать работу (включая логическую репликацию) СУБД на разных ОС, следует убедиться, что сортировка везде работает корректно.

Более серьезной потенциальной проблемой является установка новой версии библиотеки libc в ОС. Такое может произойти, например, при переходе на новый сервер с новой версией ОС. Изменение в новой версии libc используемых в базе данных правил сортировки может привести к некорректной работе индексов и другим проблемам.

# Провайдер ICU

Порядок символов

- зависит от версии библиотеки, но не от операционной системы

Использование

- явное указание при определении столбцов и в выражениях
- нельзя использовать по умолчанию для базы данных или кластера

Дополнительные возможности

- управление порядком сортировки групп символов



Для использования провайдера ICU в определении правил сортировки необходимо, чтобы PostgreSQL был собран с поддержкой этой библиотеки. Библиотека ICU и реализованные в ней правила сортировки работают одинаково на всех операционных системах.

Библиотека ICU допускает видоизменение правил сортировки без смены языка и территории. Можно указать разный порядок сортировки для отдельных групп символов. Например, символы какой группы должны идти раньше: кириллица, латиница или цифры; буквы в верхнем регистре или в нижнем.

https://icu.unicode.org/

При инициализации кластера баз данных или при создании новой БД можно указать только локали библиотеки libc. Использовать в таком качестве библиотеку ICU можно, начиная с версии PostgreSQL 15.

## Правила сортировки

При инициализации кластера в системном каталоге каждой базы данных создаются специальные объекты — правила сортировки. Они создаются на основе информации об установленных в ОС локалях.

Начальное наполнение базы правилами сортировки:

```
=> SELECT CASE collprovider
    WHEN 'd' THEN 'default'
    WHEN 'c' THEN 'libc'
    WHEN 'i' then 'icu'
  END,
  count(*)
FROM pg_collation
GROUP BY collprovider;
```

```
  case   | count
---------+-------
 icu     |   787
 libc    |    45
 default |     1
(3 строки)
```

Правила сортировки для русского языка, полученные из ОС:

```
=> \dOS+ ru*
```

```
                                      Список правил сортировки
   Схема    |     Имя     | LC_COLLATE |  LC_CTYPE  | Провайдер | Детерминированное? |       Описание
------------+-------------+------------+------------+-----------+--------------------+----------------------
 pg_catalog | ru-BY-x-icu | ru-BY      | ru-BY      | icu       | да                 | Russian (Belarus)
 pg_catalog | ru-KG-x-icu | ru-KG      | ru-KG      | icu       | да                 | Russian (Kyrgyzstan)
 pg_catalog | ru-KZ-x-icu | ru-KZ      | ru-KZ      | icu       | да                 | Russian (Kazakhstan)
 pg_catalog | ru-MD-x-icu | ru-MD      | ru-MD      | icu       | да                 | Russian (Moldova)
 pg_catalog | ru-RU-x-icu | ru-RU      | ru-RU      | icu       | да                 | Russian (Russia)
 pg_catalog | ru-UA-x-icu | ru-UA      | ru-UA      | icu       | да                 | Russian (Ukraine)
 pg_catalog | ru-x-icu    | ru         | ru         | icu       | да                 | Russian
 pg_catalog | ru_RU       | ru_RU.utf8 | ru_RU.utf8 | libc      | да                 |
 pg_catalog | ru_RU.utf8  | ru_RU.utf8 | ru_RU.utf8 | libc      | да                 |
(9 строк)
```

Правила сортировки для провайдера ICU создаются только в том случае, если сервер собран с параметром --with-icu:

```
=> SELECT unnest(regexp_match(setting,'--with-icu')) config
FROM pg_config()
WHERE name = 'CONFIGURE';
```

```
   config
------------
 --with-icu
(1 строка)
```

---

## Правила сортировки ICU

Сортировка для правила ru-x-icu отличается от используемой по умолчанию сортировки для правила ru_RU. Кириллица идет раньше латиницы:

```
=> WITH t(c) AS (
  VALUES('a'),('б'),('в'),('а'),('b'),('c'),('1'),('2'),('3')
)
SELECT string_agg(t.c,',' ORDER BY t.c) AS "default",
       string_agg(t.c,',' ORDER BY t.c COLLATE "ru-x-icu") AS "ru-x-icu"
FROM t \gx
```

```
-[ RECORD 1 ]--------------
default  | 1,2,3,a,b,c,а,б,в
ru-x-icu | 1,2,3,а,б,в,a,b,c
```

Ключевое слово COLLATE после выражения (в ORDER BY) явно задает правило сортировки. По умолчанию используется правило с именем default, соответствующее параметрам локали базы данных.

---

Возможности библиотеки ICU позволяют по-разному настраивать сортировку отдельных групп символов.

Создадим новое правило сортировки, где латинские символы идут раньше символов кириллицы:

```
=> CREATE COLLATION latn_cyrl
    (provider = icu, locale = 'ru-RU-u-kr-latn-cyrl');
```

```
CREATE COLLATION
```

Еще одно, где в дополнение к предыдущему буквы идут раньше цифр:

```
=> CREATE COLLATION latn_cyrl_digit
    (provider = icu, locale = 'ru-RU-u-kr-latn-cyrl-digit');
```

```
CREATE COLLATION
```

Проверяем сортировку:

```
=> WITH t(c) AS (
  VALUES('a'),('б'),('в'),('а'),('b'),('c'),('1'),('2'),('3')
)
SELECT string_agg(t.c,',' ORDER BY t.c) AS "default",
       string_agg(t.c,',' ORDER BY t.c COLLATE "ru-x-icu") AS "ru-x-icu",
       string_agg(t.c,',' ORDER BY t.c COLLATE "latn_cyrl") AS "latn_cyrl",
       string_agg(t.c,',' ORDER BY t.c COLLATE "latn_cyrl_digit") AS "latn_cyrl_digit"
FROM t \gx
```

```
-[ RECORD 1 ]---+------------------
default         | 1,2,3,a,b,c,а,б,в
ru-x-icu        | 1,2,3,а,б,в,a,b,c
latn_cyrl       | 1,2,3,a,b,c,а,б,в
latn_cyrl_digit | a,b,c,а,б,в,1,2,3
```

# Детерминизм

Детерминированные правила сортировки

- равенство строк при побайтовом совпадении

Недетерминированные правила сортировки

- строки, состоящие из разных байтов, могут быть равными
- дополнительная гибкость
- производительность ниже
- не поддерживают LIKE и другие операции



Правило сортировки в зависимости от типа используемого сравнения может быть детерминированным или недетерминированным.

Детерминированные сравнения считают равными строки, состоящие из одних и тех же байтов. При недетерминированном сравнении даже не совпадающие побайтово строки могут считаться равными. Например, в Unicode буква «ё» может быть представлена одним символом Cyrillic Small Letter Io (U+0451), а может быть составлена из буквы «е» (U+0435) и диакритического знака «диерезис» (U+0308).

Все стандартные правила — детерминированные. Пользовательские правила по умолчанию тоже будут детерминированными.

Недетерминированные правила дают дополнительную гибкость: можно, например, задать ограничение уникальности без учета регистра или диакритических символов. Но производительность детерминированных правил обычно выше. К тому же недетерминированные правила не поддерживают некоторые операции, такие как поиск по шаблону.

### Недетерминированные правила сортировки

Определим недетерминированное правило для регистронезависимой сортировки:

```
=> CREATE COLLATION ignore_case
  (provider = icu, locale = 'und-u-ks-level2', deterministic = false);
```

```
CREATE COLLATION
```

Теперь строки в разных регистрах могут быть равными:

```
=> SELECT
        'postgres' = 'POSTGRES' AS "default",
        'postgres' = 'POSTGRES' COLLATE "ignore_case" AS "ignore_case"
;
```

```
 default | ignore_case
---------+-------------
 f       | t
(1 строка)
```

Но поиск по шаблону для недетерминированного правила невозможен:

```
=> SELECT 'PostgreSQL' LIKE 'post%' COLLATE "ignore_case";
```

```
ОШИБКА:  недетерминированные правила сортировки не поддерживаются для LIKE
```

# Отслеживание изменений

Изменение библиотеки-провайдера приводит к проблемам

- неправильная сортировка значений в индексах
- сравнения строк в ограничениях целостности
- сравнения строк в запросах
- и т. д.

Номер версии библиотеки хранится в системном каталоге

При изменении установленной версии — предупреждение

- libc не гарантирует стабильность и платформонезависимость версии



Если при изменении библиотеки-провайдера сравнение начинает работать иначе, это может повлиять на используемые в базе данных правила сортировки и вызвать проблемы:

- неправильную работу запросов из-за нарушения сортировки значений в индексах;

- некорректные данные из-за изменившегося поведения при сравнении строк в ограничениях целостности CHECK и триггерах;

- некорректные результаты из-за изменившегося поведения сравнения строк в запросах, процедурном коде и политиках защиты строк.

Поэтому при использовании правил сортировки PostgreSQL будет предупреждать о возможных проблемах, связанных с изменением библиотек.

При создании правила текущий номер версии библиотеки сохраняется в системном каталоге. При каждом использовании правила сохраненный номер версии сверяется с текущим номером, и при обнаружении расхождения запросы будут выдавать предупреждения о несоответствии версий.

Если такая ситуация случилась, следует пересоздать индексы, использующие измененные правила сортировки, а также проверить все места, где используются правила сортировки.

Нужно помнить, что, в отличие от ICU, провайдер libc не гарантирует одинаковую работу сортировки даже при совпадении версий библиотеки.

### Изменения в библиотеках-провайдерах

При создании правила сортировки в системном каталоге сохраняется версия библиотеки, переданная операционной системой. Если в ОС изменится версия библиотеки, каждый раз при использовании правила будет выдаваться предупреждение о том, что версии не совпадают.

Проверить соответствие версий можно запросом:

```
=> SELECT c.collname,
  c.collversion AS version,
  pg_collation_actual_version(c.oid) AS actual_version
FROM pg_collation c
WHERE c.collname LIKE 'ru%';
```

```
  collname   |  version   | actual_version
-------------+------------+----------------
 ru-BY-x-icu | 153.112.40 | 153.112.40
 ru-KG-x-icu | 153.112.40 | 153.112.40
 ru-KZ-x-icu | 153.112.40 | 153.112.40
 ru-MD-x-icu | 153.112.40 | 153.112.40
 ru-RU-x-icu | 153.112.40 | 153.112.40
 ru-UA-x-icu | 153.112.40 | 153.112.40
 ru-x-icu    | 153.112.40 | 153.112.40
 ru_RU       | 2.35       | 2.35
 ru_RU       | 2.35       | 2.35
 ru_RU.koi8r | 2.35       | 2.35
 ru_RU.utf8  | 2.35       | 2.35
 russian     | 2.35       | 2.35
(12 строк)
```

Изменение правила сортировки может привести к некорректной работе индексов. Если подобное произошло, рекомендуется пересоздать индексы с новой версией правила сортировки. После этого можно обновить версию в системном каталоге командой ALTER COLLATION ... REFRESH VERSION и предупреждения перестанут выдаваться.

Запрос для получения списка объектов, которые зависят от требующих обновления правил сортировки:

```
=> SELECT pg_describe_object(refclassid, refobjid, refobjsubid) AS "Collation",
  pg_describe_object(classid, objid, objsubid) AS "Object"
FROM pg_depend d
  JOIN pg_collation c ON refclassid = 'pg_collation'::regclass AND refobjid = c.oid
WHERE c.collversion <> pg_collation_actual_version(c.oid)
ORDER BY 1, 2;
```

```
 Collation | Object
-----------+--------
(0 строк)
```

# Итоги

Перед инициализацией кластера нужные для СУБД локали должны быть установлены в ОС

Клиент и сервер могут работать в различных кодировках с автоматическим преобразованием символов

Сообщения сервера и утилит переведены на множество языков, включая русский

Правила сортировки используют внешние библиотеки, изменения в которых могут привести к повреждению данных и некорректным результатам

# Практика

1. Перенос данных между базами в разных кодировках.

   Создайте базу данных с кодировкой KOI8R.
   Создайте таблицу и добавьте в нее строки, содержащие символы кириллицы.
   Сделайте копию базы данных утилитой pg_dump.
   Восстановите таблицу из копии в базу с кодировкой UTF8.

2. Получите номер сегодняшнего дня недели.

   Меняется ли номер дня недели в зависимости от настроек локализации?



1. Для создания БД в кодировке KOI8R:

- убедитесь, что в ОС установлена нужная локаль;

- в команде CREATE DATABASE используйте шаблон template0 параметры ENCODING и LOCALE.

2. Для получения номера дня недели используйте функцию to_char.

Допустимые форматные маски даты:

https://postgrespro.ru/docs/postgresql/13/functions-formatting#FUNCTIONS-FORMATTING-DATETIME-TABLE

## 1. Кодировки базы данных

Проверим, что в ОС есть локали с кодировкой koi8:

```
=> \! locale -a | grep koi8
```

```
ru_RU.koi8r
```

Создаем базы данных с кодировками KOI8R и UTF8:

```
=> CREATE DATABASE admin_localization_koi8r
  TEMPLATE template0
  ENCODING 'koi8r'
  LOCALE 'ru_RU.koi8r';
```

```
CREATE DATABASE
```

```
=> CREATE DATABASE admin_localization_utf8;
```

```
CREATE DATABASE
```

```
=> \l admin_localization_*
```

```
                                    List of databases
           Name           |  Owner  | Encoding |   Collate   |    Ctype    | Access privileges
--------------------------+---------+----------+-------------+-------------+-------------------
 admin_localization_koi8r | student | KOI8R    | ru_RU.koi8r | ru_RU.koi8r |
 admin_localization_utf8  | student | UTF8     | en_US.UTF-8 | en_US.UTF-8 |
(2 rows)
```

Подключаемся к базе с кодировкой KOI8R:

```
=> \c admin_localization_koi8r
```

```
You are now connected to database "admin_localization_koi8r" as user "student".
```

```
=> SET client_encoding = 'UTF8';
```

```
SET
```

Убедимся, что клиент и сервер используют разные кодировки:

```
=> SELECT name, setting
FROM pg_settings
WHERE name LIKE '%encoding';
```

```
      name       | setting
-----------------+---------
 client_encoding | UTF8
 server_encoding | KOI8R
(2 rows)
```

Создаем таблицу, содержащую строки с кириллицей:

```
=> CREATE TABLE tab AS
  SELECT 'Привет, мир!' AS col;
```

```
SELECT 1
```

```
=> SELECT * FROM tab;
```

```
     col
--------------
 Привет, мир!
(1 row)
```

```
=> \q
```

Получаем логическую копию:

```
student$ pg_dump -d admin_localization_koi8r -Fc -f koi8r.dump
```

Содержимое копии выгружается в кодировке базы данных (KOI8R), а в начале файла есть команда установки параметра client_encoding в то же значение KOI8R.

Восстанавливаем таблицу в базе данных admin_localization_utf8:

```
student$ pg_restore koi8r.dump -d admin_localization_utf8 -t tab
```

Благодаря установке client_encoding при восстановлении символы автоматически перекодируются. Проверим, что кириллица корректно перенесена:

```
student$ psql -d admin_localization_utf8
```

```
=> SELECT * FROM tab;
```

```
     col
-------------
 Привет, мир!
(1 row)
```

## 2. Номер сегодняшнего дня недели

Текущие настройки локализации даты и времени:

```
=> SHOW lc_time;
```

```
   lc_time
-------------
 ru_RU.UTF-8
(1 row)
```

Для получения номера дня недели есть две форматные маски:

- ID — неделя начинается с понедельника;
- D — неделя начинается с воскресенья.

```
=> SELECT to_char(current_date, 'TMDay: ID') AS "ID",
          to_char(current_date, 'TMDay: D') AS "D" ;
```

```
     ID     |     D
------------+------------
 Пятница: 5 | Пятница: 6
(1 row)
```

Номер дня недели не зависит от настроек локализации, в частности, от параметра lc_time:

```
=> SET lc_time TO 'en_US.utf8';
```

```
SET
```

```
=> SELECT to_char(current_date, 'TMDay: ID') AS "ID",
          to_char(current_date, 'TMDay: D') AS "D" ;
```

```
    ID     |     D
-----------+-----------
 Friday: 5 | Friday: 6
(1 row)
```