Temat zajęć: Filtry, strumienie standardowe oraz przetwarzanie potokowe

Czas realizacji zajęć:	*180 min.*
Zakres materiału, jaki zostanie zrealizowany podczas zajęć:	Strumienie standardowe i ich przekierowywanie, podstawowe filtry, przetwarzanie potokowe z zastosowaniem filtrów.

I. Standardowe wejście/wyjście

Każdy proces domyślnie korzysta ze standardowych strumieni danych, będących abstrakcją źródła lub ujścia danych. Dla każdego procesu system tworzy standardowy strumień wejściowy (ang. *standard input*), reprezentujący urządzenia wejściowe, np. klawiaturę i dysk, standardowy strumień wyjściowy (ang. *standard output*), którym może być terminal (monitor komputera) lub plik oraz strumień diagnostyczny (ang. *standard error*). Strumienie wejściowy, wyjściowy i diagnostyczny oznaczane są odpowiednio: `stdin`, `stdout`, `stderr`. Każdy strumień ma odpowiadające mu wartości: `stdin` – 0, `stdout` – 1 i `stderr` – 2.

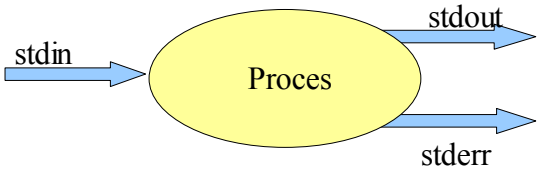

Rysunek 1: Standardowe wejście/wyjście procesu

Standardowe strumienie procesów charakteryzują się następującymi cechami:
1. Dane odczytywane są poprzez standardowe wejście.
2. Dane wypisywane są na standardowym wyjściu lub standardowym wejściu diagnostycznym.
3. Raz przeczytanych danych nie można ponownie przeczytać.

Działanie standardowych strumieni ilustruje program `cat`. Uruchomienie tego programu bez argumentów powoduje przepisanie tego, co zostanie wpisane z klawiatury na ekran. Polecenie to można zakończyć za pomocą kombinacji Ctrl-D.

II. Przekierowanie wejścia/wyjścia procesów

Istnieje możliwość przeadresowania strumieni wyjściowych i wejściowych. Zmianę standardowego wejścia, wyjścia i wyjścia diagnostycznego można dokonać za pomocą operatorów: >, <, >>, <<.

Operator > powoduje przeadresowanie standardowego wyjścia, czyli utworzenie pliku i zapisanie w nim tego, co proces wypisałby na standardowym wyjściu. Jeśli wskazany plik już istnieje, zostanie on usunięty i utworzony na nowo.

```
%cat > plik.txt
To jest plik.
```

```
Ala ma kota.
^D
```

Operator < powoduje przeadresowanie standardowego wejścia procesu, czyli pobranie danych wejściowych ze wskazanego pliku:

```
%cat < plik.txt
To jest plik.
Ala ma kota.
```

Operatory > i < można używać jednocześnie, przeadresowując zarówno wyjście jak i wejście, co spowoduje, że zawartość pliku *plik.txt* zostaje skopiowana do pliku *plik_nowy.txt:*

```
%cat < plik.txt > plik_nowy.txt
```

Operator >> przeadresowuje standardowe wyjście, dopisując wyniki działania programu na końcu istniejącego pliku:

```
%cat >> plik.txt
Kot ma Ale.
^D
```

Operator << powoduje, że do procesu zostaną przekazane dane ze standardowego wejścia aż do napotkania wskazanego napisu:

```
%cat <<  przerwa
> Ala ma kota
> Kot ma Ale
> przerwa
Ala ma kota
Kot ma Ale.
```

Niektóre polecenia równolegle z wyświetlanymi na standardowym wyjściu informacjami wysyłają dodatkowe informacje informujące o błędach przetwarzania na standardowe wyjście diagnostyczne. Istnieje możliwość niezależnego przekierowania strumienia diagnostycznego, poprzez operator > poprzedzony numerem wyjścia diagnostycznego, czyli 2:

```
%cat plik1.txt plik2.txt 2> plik3.err
```

Polecenie to spowoduje wyświetlenie zawartości plików *plik1.txt* i *plik2.txt* oraz zapisanie informacji o błędach do pliku *plik3.err.*

W celu pominięcia komunikatów o błędach, wyjście diagnostyczne można przeadresować do pliku /dev/null. Wszystko co zostaje wysłane do pliku null, znajdującego się w katalogu /dev zostanie utracone:

```
%cat plik1.txt plik2.txt> plik3.txt 2> /dev/null
```

Polecenie to spowoduje zapisanie zawartości plików *plik1.txt* i *plik2.txt* do pliku *plik3.txt* oraz jednocześnie zignoruje komunikaty o błędach.

W przypadku gdy strumień diagnostyczny ma trafiać tam, gdzie strumień wyjściowy, należy użyć zapisu `2>&1`:

```
%cat plik1.txt plik2.txt> plik3.txt 2>&1
```

III. Przetwarzanie potokowe

Standardowe wyjście jednego procesu możne być połączone ze standardowym wejściowym innego procesu, tworząc tzw. potok pomiędzy tymi procesami.

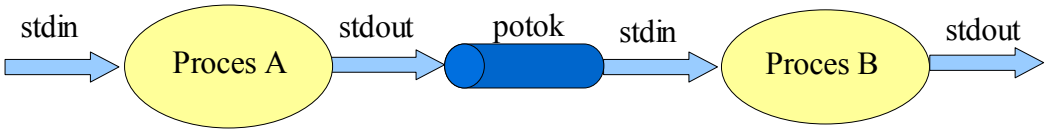

Rysunek 2: Potok

Przetwarzanie potokowe polega na buforowaniu przez system danych produkowanych przez pierwszy proces i następnie odczytywaniu tych danych przez drugi proces. Innymi słowy proces w potoku czyta dane z wejścia, które zostało przeadresowane na wyjście procesu poprzedniego. W potoku może brać udział jednocześnie kilka procesów. Poniżej podano przykłady potoków:

1. Proces `ls` podaje wynik procesowi `more`, który w efekcie wyświetla listing strona po stronie:
   `ls – al|more`
2. Proces `who` podaje wynik procesowi `sort`, podając posortowaną listę pracowników pracujących w systemie:
   `who|sort`
3. Proces `ps` podaje wynik procesowi `grep`, wyszukując na liście procesów linii zawierających słowo csh:
   `ps -ef|grep csh`
4. Proces `ls` podaje wynik procesowi `sort`, który następnie podaje wynik procesowi `head`, wyświetlając pierwszych 10 najmniejszych plików:
   `ls -l /usr/bin|sort -bnr +4 -5|head.`

IV. Filtry

Istnieją programy, których zadaniem jest odczyt danych ze standardowego wejścia, przetworzenie tych danych i ich zapis na standardowe wyjście. Programy takie nazywane są filtrami i są szeroko wykorzystywane w przetwarzaniu potokowym. Poniżej przedstawiono najczęściej wykorzystywane filtry:

`cat` – najprostszy filtr, nie wprowadzający zmian do przetwarzanych danych. Użyteczne

przełączniki:

`–s` z paru pustych linii robi jedna

`–n` numeruje wszystkie linie

`–b` numeruje niepuste linie

`-A` pokazuje znaki specjalne

`head` – wyświetla początkową część pliku o podanej nazwie lub danych wejściowych otrzymanych z potoku gdy nazwa pliku nie jest podana. Standardowo wyświetlanych jest pierwszych 10 linii odczytanych danych. Używając przełączników liczbę tą można zmienić:

`–c` pozwala określić liczbę wyświetlanych znaków

`-n` pozwala określić liczbę wyświetlanych linii

`tail` – wyświetla końcową część pliku o podanej nazwie lub danych wejściowych otrzymanych z potoku, gdy nazwa pliku nie jest podana,. Standardowo wyświetlanych jest ostatnich 10 linii danych. Używając przełączników liczbę tą można zmienić:

`–c` pozwala określić liczbę wyświetlanych znaków

`-n` pozwala określić liczbę wyświetlanych linii

`-f` powoduje, że dane po zapisaniu ich do pliku są wyświetlane na standardowym wyjściu

`sort` – służy do sortowania danych wejściowych, które domyślnie sortowane są leksykograficznie. Sortowanie danych odbywa się liniami. Najważniejsze przełączniki:

`–n` pozwala sortować numerycznie

`–b` ignoruje przy sortowaniu spacje znajdujące się na początku linii

`-t` pozwala zmienić domyślny separator kolumn, którym są znaki tabulacji lub spacji

`-f` pozwala ignorować przy sortowaniu wielkość liter

`-r` odwraca kolejność sortowania

`+liczba` pozwala by sortowanie odbywało się względem dowolnej kolumny (a nie początku linii). Liczba określa liczbę kolumn pominiętych przy sortowaniu

`-o nazwa_pliku` zapisuje rezultat sortowania do pliku o podanej nazwie

`uniq` – umozliwia usunięcie powtarzających się, sąsiadujących linii danych wejściowych.

`–d` wyświetla z danych wejściowych tylko linie powtarzające się

`–u` wyświetla z danych wejściowych tylko linie unikalne

`–c` zlicza liczbę powtórzeń

wc – zlicza znaki, słowa i linie w podanych danych wejściowych. Standardowo wyświetlane są wszystkie trzy wartości, ale można to zmienić:

- `-l` pozwala zliczać tylko linie
- –w pozwala zliczać tylko słowa
- `-c` pozwala zliczać tylko znaki

tr – pozwala zamienić łańcuchy tekstowe, które podawane są jako argumenty wejściowe. Znaki z pierwszego łańcuch zamieniane są na znaki z drugiego łańcucha. Dodatkowo, dzięki przełącznikom możliwe jest następujące przetwarzanie:

- `-d` usuwa podane po przełączniku znaki
- `-s` usuwa powtarzające się sąsiednie znaki

cut – pozwala wyświetlić fragmenty wierszy danych wejściowych. Zwykle jest to wycinanie odpowiednich kolumn.

- `-c` pozwala określić pozycję znakowe wycinanych fragmentów wierszy, np. -c 1-72 wyświetla pierwsze 72 znaki każdego wiersza
- –f pozwala określić numery wycinanych kolumn, np. -f1,3-5,10 wyświetla pierwszą kolumnę, kolumny od 3 do 5 oraz kolumnę 10.
- `-d` pozwala zmienić domyślny separator kolumn, którym jest znak tabulacji

grep `[opcje] wyrażenie [lista_plików]-` przeszukuje dane pochodzące ze standardowego wejścia lub pliki wyszczególnione na liście plików, wypisując tylko linie zawierające szukane wyrażenie. Szukane wyrażenie zapisywane jest za pomocą wyrażenia regularnego. Najważniejsze przełączniki:

- `-v` wyszukuje linie nie zawierające szukanego wzorca
- `-c` podaje liczbę odszukanych wyrażeń
- `-i` ignoruje wielkość liter przy wyszukiwaniu
- `-n` wyświetla numery linii zawierających dany wzorzec
- `-h` przy wyświetlaniu linii zawierających szukany wzorzec pomija nazwy plików
- `-r` pozwala na przeszukiwanie rekurencyjne, np. grep wzorzec –r katalog
- `-l` pokazuje nazwy plików zawierających określony wzorzec
- `-L` pokazuje nazwy plików nie zawierających określonego wzorca

Zasady konstrukcji podstawowych wyrażeń regularnych opisujących szukany wzorzec są następujące:

`.` – reprezentuje dowolny znak
`[abc]` – oznacza jeden ze znaków `a, b` lub `c`
`[a-z]-` oznacza jeden ze znaków z podanego zbioru
`[^0-9]` – oznacza dopełnienie podanego zbioru
`.*` - oznacza dowolny ciąg znaków
`*` - reprezentuje powtórzenie dowolną liczbę razy wyrażenia znajdującego się

bezpośrednio po lewej stronie np. (`A[a]*` określa `A, Aa, Aaa, Aaaaaaaaa`, itd.)

`^` – reprezentuje początek linii

`$` – reprezentuje koniec linii

`a\{n\}` – oznacza n-krotne wystąpienie znaku występującego bezpośrednio po lewej stronie nawiasów

`a\{n, \}` - oznacza co najmniej n-krotne wystąpienie znaku występującego bezpośrednio po lewej stronie nawiasów

`a\{, m\}` – oznacza co najwyżej m-krotne wystąpienie znaku występującego po lewej stronie nawiasów

`a\{n,m\}` - oznacza co najmniej n-krotne i co najwyżej m-krotne wystąpienie znaku występującego po lewej stronie nawiasów

Dodatkowo istnieje specjalna grupa znaków mająca znaczenie specjalne. Do znaków tych należą: `. * {} () ^ [ ] \ < > $` . W celu wykorzystania tych znaków jako zwykłych znaków, należy je poprzedzić znakiem "\".

Oprócz podstawowych wyrażeń regularnych istnieją wyrażenia rozszerzone, pozwalające w krótszy sposób opisać poszukiwane wyrażenie i oferujące bogatsze możliwości opisu wyrażeń. W celu użycia rozszerzonych wyrażeń regularnych, należy polecenie grep użyć z przełącznikiem – E, lub wykorzystać polecenie **`egrep`**.

V. Zadania do samodzielnego wykonania.

Wyświetl plik `/etc/passwd` z podziałem na strony przyjmując, że strona ma 5 linii tekstu.

1) Korzystając z polecenia `cat` utwórz plik *tekst3*, który będzie składał się z zawartości pliku *tekst1*, ciągu znaków podanego ze standardowego wejścia (klawiatury) i pliku *tekst2*.
2) Wyświetl po 5 pierwszych linii wszystkich plików w swoim katalogu domowym w taki sposób, aby nie były wyświetlane ich nazwy.
3) Wyświetl linie o numerach 3, 4 i 5 z pliku `/etc/passwd`
4) Wyświetl linie o numerach 7, 6 i 5 od końca pliku `/etc/passwd`
5) Wyświetl zawartość `/etc/passwd` w jednej linii
6) Za pomocą filtru `tr` wykonaj modyfikację pliku, polegającą na umieszczeniu każdego słowa w osobnej linii.
7) Zlicz wszystkie pliki znajdujące się w katalogu `/etc` i jego podkatalogach
8) Napisać polecenie zliczające sumę znaków z pierwszych trzech linii pliku `/etc/passwd`
9) Wyświetl listę plików z aktualnego katalogu, zamieniając wszystkie małe litery na duże.
10) Wyświetl listę praw dostępu do plików w aktualnym katalogu, ich rozmiar i nazwę
11) Wyświetl listę plików w aktualnym katalogu, posortowaną według rozmiaru pliku
12) Wyświetl zawartość pliku `/etc/passwd` posortowaną wg numerów `UID` w kolejności od największego do najmniejszego
13) Wyświetl zawartość pliku `/etc/passwd` posortowaną najpierw wg numerów `GID` w kolejności od największego do najmniejszego, a następnie UID

14) Podaj liczbę plików każdego użytkownika
15) Sporządź statystykę praw dostępu (dla każdego z praw dostępu podaj ile razy zostało ono przydzielone)
16) Podaj nazwy trzech najmniejszych plików w katalogu posortowane wg nazwy
17) Podaj pięciu użytkowników o największej liczbie uruchomionych procesów
18) Wyświetl zawartość 3 największych podkatalogów katalogu bieżącego
19) Wyświetl nazwy tych użytkowników, którzy domyślnie używają innego interpretera niż `bash`
20) Wyświetl nazwy wszystkich plików nagłówkowych posortowane wykorzystywanych w plikach bieżącego katalogu
21) Wyświetl statystykę używanych komend (bez argumentów) w postaci posortowanej listy: ilość komenda (wsk. należy użyć polecenia `history`)
22) W podanym katalogu utwórz podkatalogi wszystkim użytkownikom ze swojego roku i dodatkowo zapisz w pliku o nazwie users.txt posortowaną listę tych użytkowników.
23) Sprawdź czy któryś z użytkowników jest zalogowany w systemie więcej niż jeden raz. Dla każdego takiego użytkownika należy wyświetlić jego identyfikator i listę terminali na których pracuje.

VI. Literatura.

[Sob01] Sobaniec C., *Linux. Podręcznik Użytkownika.*, Wydawnictwo NAKOM, 2001, ISBN 83-86969-53-9.