

**Zadanie 5**

W całym rozwiązaniu przyjmuję alfabet zgodny z treścią zadania. Słowa wczytywane przez automat  $A_n$  utożsamiamy ze ścieżkami przechodzonymi przez automat (jest to możliwe, gdyż duży rozmiar alfabetu pozwala łatwo z kolejnych stanów otrzymać słowo, które automat wczytał). Zauważmy, że wszystkie podwyrażenia szukanego wyrażenia  $E$  muszą generować jedynie słowa, które są legalne dla automatu  $A_n$  zaczynającego pracę w pewnym stanie (tzn. podwyrażenie  $E$  nie może być np. postaci  $a_{12}a_{32}$ , gdyż wtedy w  $L(E)$  znalazłoby się słowo, którego nie może tam być – trudno mi jaśniej sformułować tę własność).

Niech  $E$  będzie wyrażeniem regularnym. Niech  $S$  będzie zbiorem ścieżek w automacie  $A_n$  dla pewnego  $n$ . Powiemy, że wyrażenie  $E$  opisuje zbiór ścieżek  $S$  jeśli słowa z języka  $L(E)$  są utożsamione ze ścieżkami z  $S$  (nieformalnie możemy napisać  $L(E)=S$ ). Niech  $p$  będzie dowolną, niepustą ścieżką w grafie automatu. Powiemy, że  $S$  pokrywa ścieżkę  $p$  jeśli istnieje taka ścieżka  $q$  należąca do  $S$ , że  $p$  jest podścieżką  $q$  (tzn.  $p=uqw$  dla pewnych  $u$  i  $w$ ). Wyrażenie  $E$  pokrywa  $p$  jeśli zbiór ścieżek opisywany przez  $E$  pokrywa  $p$ .

**Lemat 1:**

Jeśli  $E$  pokrywa  $p^k$  dla pewnego  $k > 2|E|$ , to  $E$  pokrywa też każde słowo postaci  $p^*$ .

**Dowód:**

Rozpatrzmy automat skończony równoważny wyrażeniu  $E$  o minimalnej liczbie stanów (oznaczymy ten automat  $A$ ). Na mocy twierdzenia z wykładu, ten automat ma mniej niż  $2|E|$  stanów. Automat  $A$  akceptuje słowo  $up^kw$  dla pewnych  $u$  i  $w$ . Ponieważ  $k$  jest większe od liczby stanów automatu, to podczas wczytywania  $up^kw$ , z zasady szufladowej Dirchleta, dla pewnych  $i$  i  $j$ , po wczytaniu prefiksów  $up^i$  i  $up^jp^j$ , automat znajduje się w tym samym stanie. Stąd  $A$  akceptuje wszystkie słowa postaci  $up^i(p^j)^*p^{k-i-j}w$ . Zatem  $E$  (przez równoważność z  $A$  pokrywa każde słowo postaci  $p^*$ . Co kończy dowód lematu.

Największe  $k$  takie, że  $E$  pokrywa  $p^k$  oznaczmy przez  $k(E,p)$  ( $k(E,p)$  nie musi więc istnieć).

**Lemat 2:**

Jeśli  $k(E,p)$  nie istnieje, to istnieje takie  $X^*$ , które jest podwyrażeniem  $E$ , że  $k(X,p)$  istnieje, ale  $k(X^*,p)$  nie istnieje.

**Dowód:**

Weźmy  $Y$  jako minimalne podwyrażenie  $E$ , dla którego  $k(Y,p)$  nie istnieje. Zauważmy najpierw, że  $Y$  nie może być symbolem z alfabetu (gdyż wtedy  $k(Y,p)$  zawsze istnieje). Gdy  $Y=A+B$  lub  $Y=AB$  i istnieją  $k(A,p)$  oraz  $k(B,p)$ , to istnieje również  $k(Y,p)$  – zatem  $Y$  nie może być także sumą ani złożeniem podwyrażeń. Pozostaje przypadek, gdy  $Y=X^*$ . Ten  $X$  spełnia tezę lematu, ze względu na sposób wyboru  $Y$ . Co kończy dowód lematu.

Pokażemy przez indukcję, że dla każdej liczby naturalnej  $n$  istnieje ścieżka  $p$ , której początek i koniec są równe  $1$ , taka, że jeśli  $E$  pokrywa  $p$ , to  $|E| \geq 2^{n-1}$ . Oczywiście wtedy teza głównego twierdzenia będzie natychmiastowa: słowo utożsamione z  $p$  należy do  $L(A_n)$ , więc każde wyrażenie  $E$  takie, że  $L(E)=L(A_n)$  musi pokrywać  $p$ . Zatem jego długość musi być nie mniejsza niż np.  $(1,5)^n$  (dla odpowiednio dużych  $n$ ).

Dla  $n=1$  teza indukcyjna jest trywialna ( $p$  jest ścieżką jednoelementową).

Przyjmijmy, że mamy ścieżkę  $p$  spełniającą tezę dla  $n-1$ . Niech  $p_k$  będzie ścieżką powstałą z  $p$  przez permutację wierzchołków automatu  $i \mapsto (i+k) \bmod n$ . Zauważmy, że  $p_k$  ma wtedy początek w stanie  $k$  oraz nie przechodzi przez stan  $(k-1) \bmod n$ . (dalsza arytmetyka na indeksach  $p_k$  odbywa się implícite modulo  $n$ ). Rozpatrzmy ścieżkę:

$$q = p_1^m a_{12} p_2^m a_{23} \dots p_n^m a_{n1}, \text{ gdzie } m=2^n.$$

Niech wyrażenie  $E$  pokrywa  $q$ . Oczywiście wtedy dla każdego  $i$ , gdy  $k(E,p_i)$  istnieje, to  $k(E, p_i) \geq 2^n$ .

Na mocy lematu 1, gdy  $k(E,p_i)$  istnieje, to  $2|E| > k(E,p_i)$ , więc albo  $|E| \geq 2^{n-1}$  (co kończy dowód kroku indukcyjnego), albo dla wszystkich  $i$  wartość  $k(E,p_i)$  nie istnieje.

W takim razie, na mocy poczynionych wcześniej obserwacji, możemy w  $E$  wybrać dla każdego  $i$  minimalne podwyrażenie  $X_i^*$ , że  $k(X_i^*,p_i)$  nie istnieje. Spośród tych podwyrażeń wybierzmy wyrażenie minimalne w sensie długości i oznaczmy  $X^*$ . Ponieważ  $X$  jest podwyrażeniem  $E$ , to na mocy poczynionej na początku uwagi, pierwszym symbolem każdego ze słów z  $L(X)$  musi być  $a_{jk}$  dla ustalonego  $j$  i dowolnego  $k$  (inaczej część generowanych przez  $L(E)$  słów nie mogłaby być opisem przejść  $A_n$ ). Ten ustalony wierzchołek nazywać będziemy  $j$  (wierzchołek początkowy) również w dalszym wywodzie. Spośród  $X_i^*$  pokrywających  $p_{j+1}$  wybierzmy jedno, oznaczmy je  $Y^*$ . Jeśli  $X^*$  i  $Y^*$  są rozłącznymi podwyrażeniami  $E$ , to ponieważ każde z nich

jest długości przynajmniej  $2^{n-2}$  (na mocy założenia indukcyjnego), więc  $|E| \geq |X| + |Y| \geq 2^{n-1}$ , co kończy dowód. W przeciwnym razie,  $Y^*$  musi być podwyrażeniem (być może niewłaściwym)  $X^*$  (ponieważ zarówno  $X^*$  jak  $Y^*$  wybraliśmy spośród  $X_i^*$ , zaś  $X^*$  miało być najkrótsze). Weźmy wyrażenie  $Z^*$  powstałe przez podstawienie w  $Y^*$  pod  $X^*$  symbolu  $\varepsilon$ . Wtedy  $Z^*$  pokrywa  $p_{j+1}$ , ponieważ  $Y^*$  pokrywało  $p_{j+1}$ , a  $p_{j+1}$  nie przechodzi przez  $j$  – wierzchołek początkowy wyrażenia  $X^*$ . Zatem z założenia indukcyjnego mamy  $|Z^*| \geq 2^{n-2}$ . Wyrażenie  $Y^*$  jest dłuższe od  $Z^*$  o długość podstawionego wyrażenia  $X^*$ , zatem jest długości przynajmniej  $2^{n-1}$ . Z kolei  $Y^*$  jest podwyrażeniem  $E$ , więc również  $|E| \geq 2^{n-1}$ . cnd.