Expressões Regulares

Expressões Regulares (ER)

Conversão de AF para ER no JFLAP

Equivalências entre AFD, AFND, AF-λ (AF com movimentos nulos), ER, GR

Expressões Regulares (ER)

Uma ER sobre um alfabeto Σ é definida como:

a) $\varnothing$ é uma ER e denota a linguagem vazia
b) λ é uma ER e denota a linguagem contendo a palavra vazia, ie $\{\lambda\}$
c) Qualquer símbolo $x \in \Sigma$ é uma ER e denota a linguagem $\{x\}$
d) Se r e s são ER denotando as linguagens R e S então:
   - (r+s) ou (r|s) é ER e denota a linguagem $R \cup S$
   - (rs) é ER e denota a linguagem $RS = \{w \mid u \in R \text{ e } v \in S\}$
   - (r*) é ER e denota a linguagem R^*

Exemplos

1. 00 é uma ER denotando a linguagem {00}

2. (0+1)* denota a linguagem formada por todas as cadeias de 0´s e 1´s = {λ, 0, 1, 00,01,10,11,000,...] Pode ser também (a*b*)*

3. (0+1)* 00 (0+1)* denota todas as cadeias de 0´s e 1´s com ao menos dois 0´s consecutivos

4. a+b*c denota um único a e todas as cadeias consistindo de zero ou mais vezes b seguido de c. A linguagem é formada por {a, c, bc, bbc, bbbc, ...}

Exemplo 4 - JFLAP

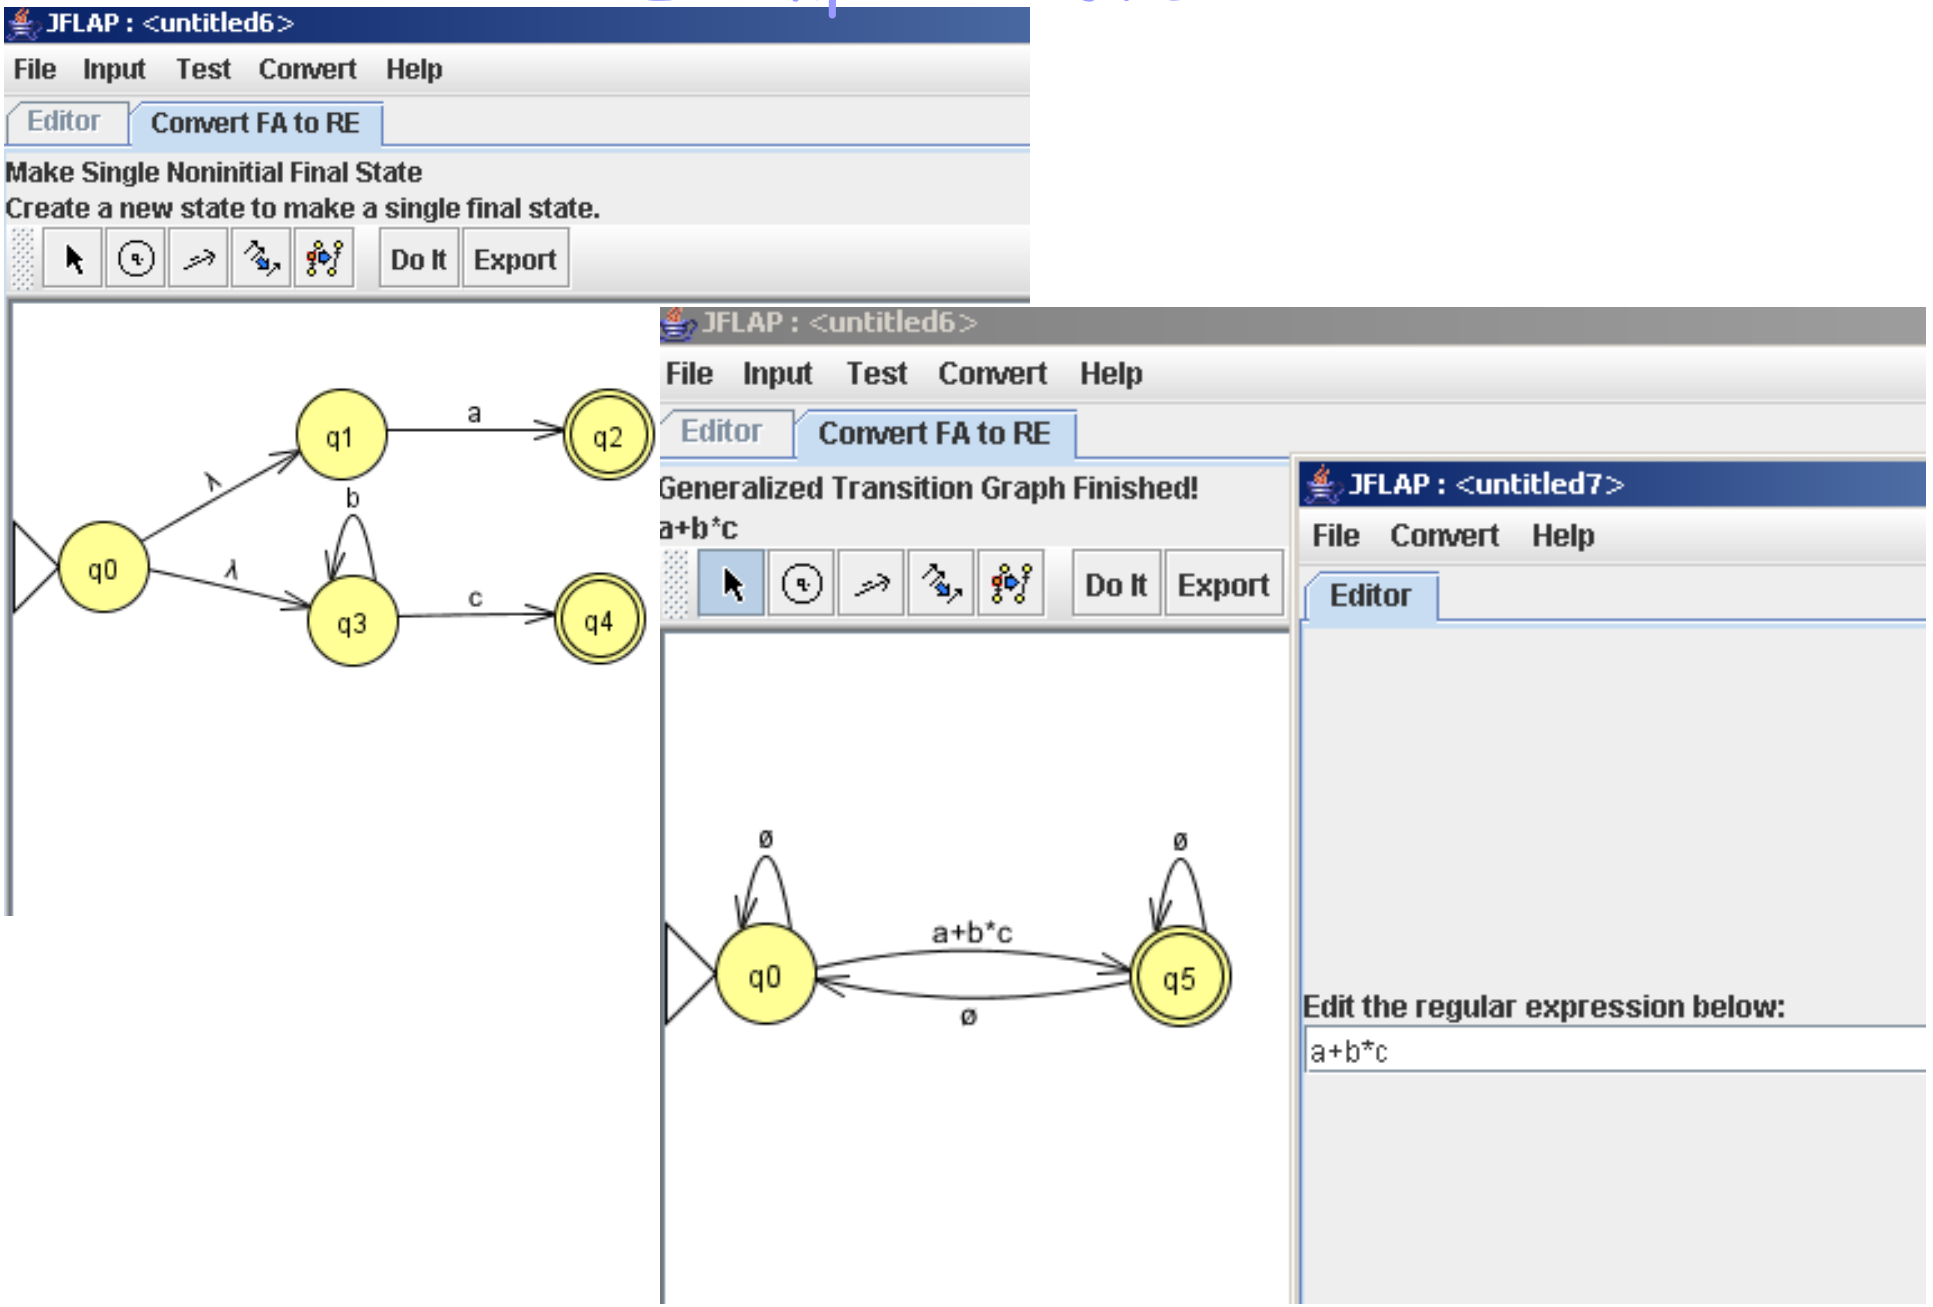

- (0+1)* 001 denota todas as cadeias de 0´s e 1´s terminadas em 001

- 0*1*2* denota qualquer número de 0´s seguido por qualquer número de 1´s seguido por qualquer número de 2´s

- 01* + 10* denota a linguagem consistindo de todas as cadeias que são um único 0 seguido por qualquer número de 1´s e um único 1 seguido por qualquer número de 0´s = {0,01,011,…,1,10,100,…}

01* + 10*

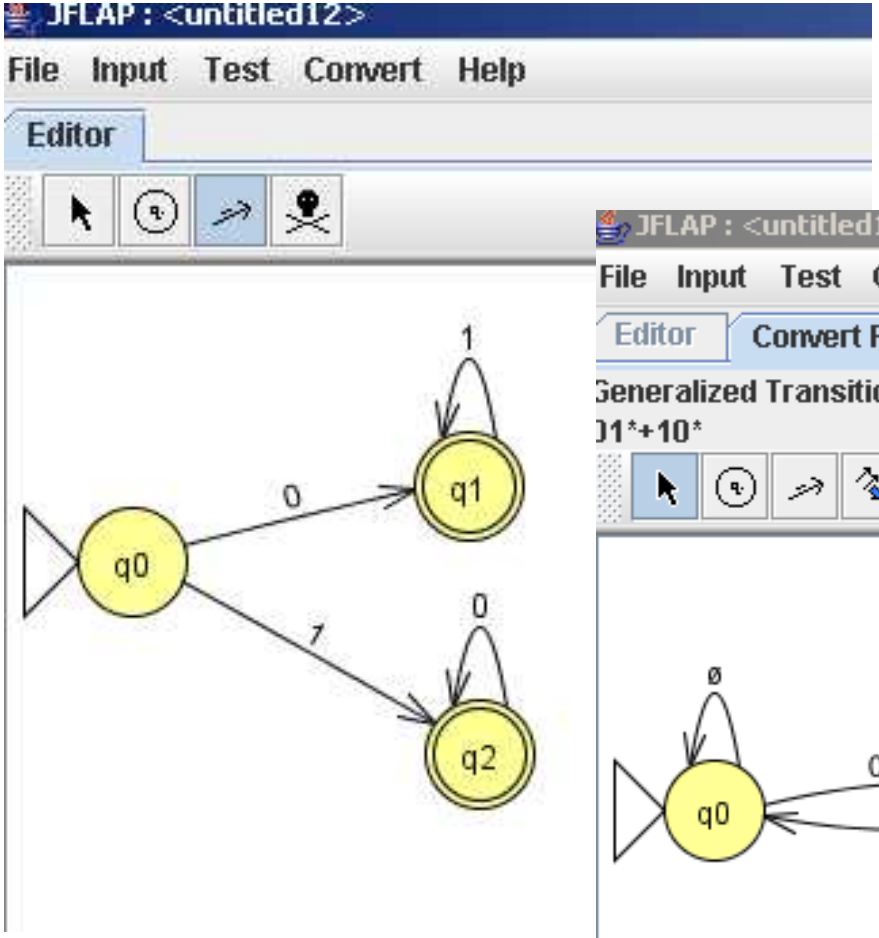
JFLAP : <untitled12>
File Input Test Convert Help
Editor
1
0
q0
q1
0
1
q2

AFD

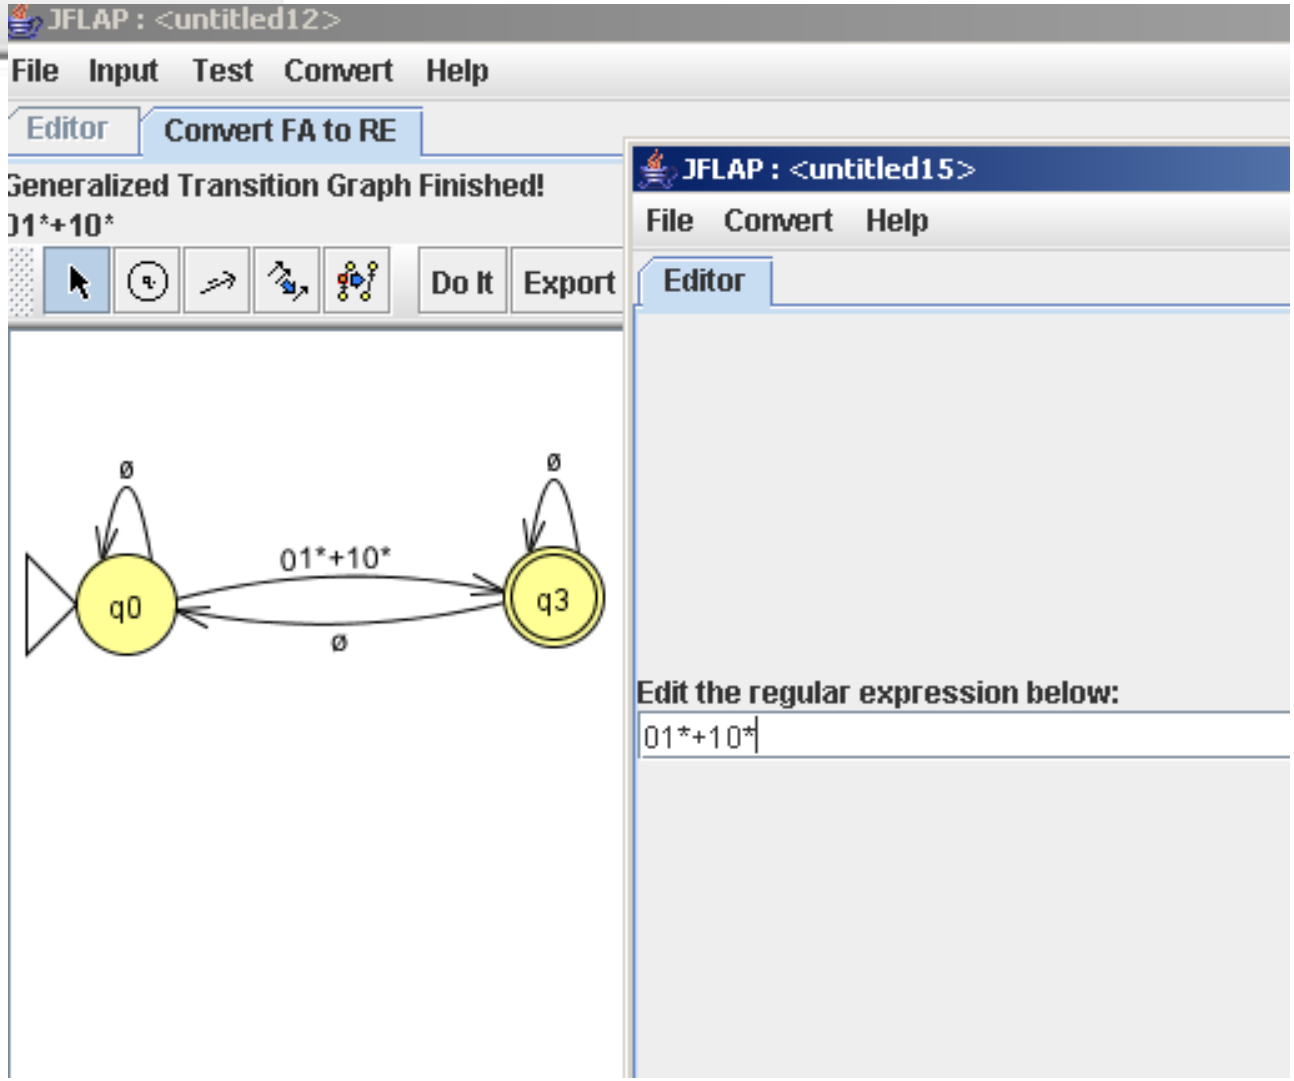
JFLAP : <untitled12>
File Input Test Convert Help
Editor
Convert FA to RE
Generalized Transition Graph Finished!
01*+10*
Do It
Export
ø
ø
q0
01*+10*
q3
ø
JFLAP : <untitled15>
File Convert Help
Editor
Edit the regular expression below:
01*+10*

01* + 10*

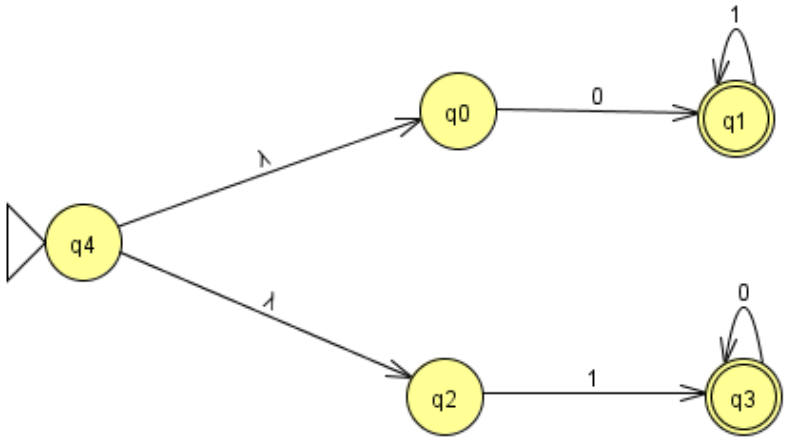
q0
q1
q2
q3
q4
λ
λ
0
1
1
0

AF-λ

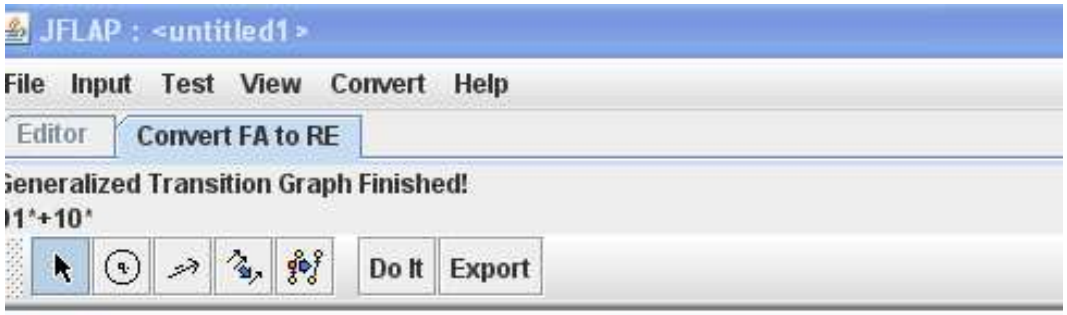
JFLAP : <untitled1>
File Input Test View Convert Help
Editor
Convert FA to RE
Generalized Transition Graph Finished!
01*+10*
Do It
Export

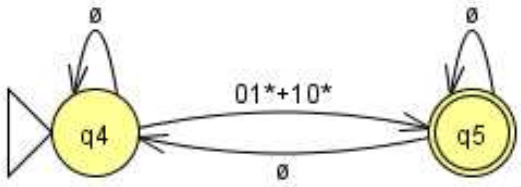
q4
q5
01*+10*
ø
ø
ø

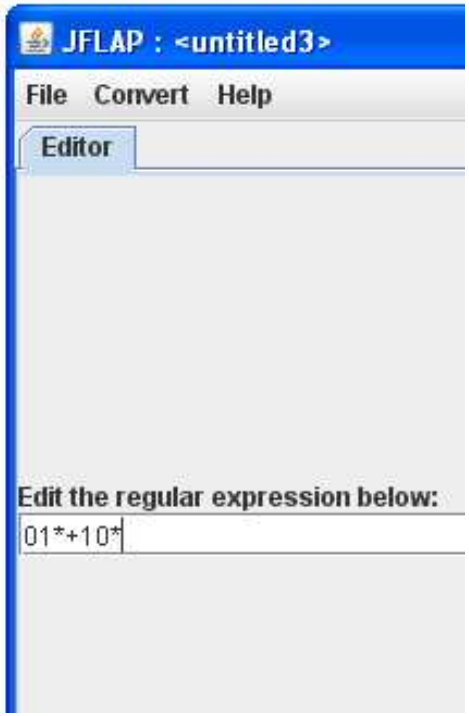
JFLAP : <untitled3>
File Convert Help
Editor
Edit the regular expression below:
01*+10*

Omissão de parênteses

- Para omitir parênteses devemos respeitar:
  - O fecho (*) tem prioridade sobre a concatenação (rs) que tem prioridade sobre a união.
  - A concatenação e a união são associadas da esquerda para a direita.
  - Ex: $01^* + 1$ é agrupado como $(0(1^*)) + 1$ => $L = \{1, 0, 01, 011, \ldots\}$

- Usamos parênteses quando queremos alterar a prioridade:

- $(01)^* + 1$ => $L = \{1 \cup (01)^n \mid n >= 0\} = \{1, \lambda, 01, 0101, \ldots\}$

- $0(1^* + 1)$ => $L = \{w \in \{0,1\}^* \mid w$ começa com 0 seguido de $1^n \mid n>=0\}$ ➔ Lei distributiva à esq = $01^* + 01 = \{0,01,011,0111,\ldots\}$

Exercícios

1. O conjunto de cadeias sobre {0,1} que termine com três 1´s consecutivos.

2. O conjunto de cadeias sobre {0,1} que tenha ao menos um 1.

3. O conjunto de cadeias sobre {0,1} que tenha no máximo um 1.

Exemplo 3

- O conjunto de cadeias sobre {0,1} que tenha no máximo um 1.

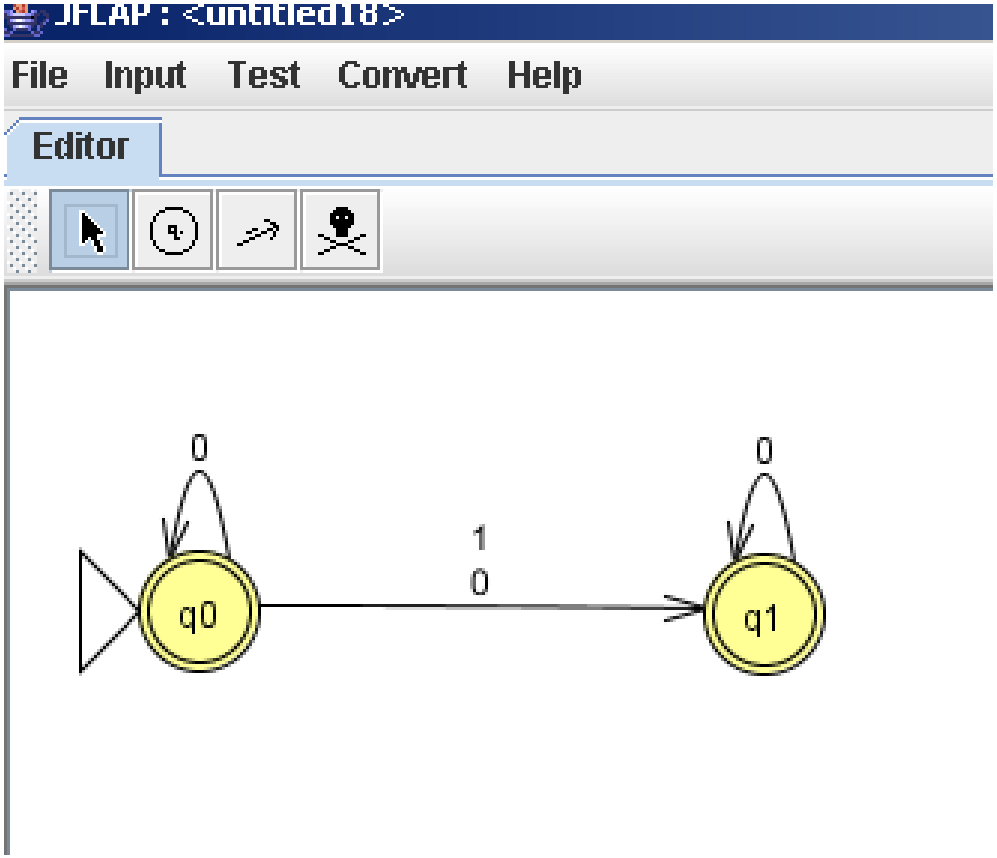

0*(λ+(0+1)0*) →
podem usar λ para simplificar a ER que seria:

0* (1+0) 0* + 0*

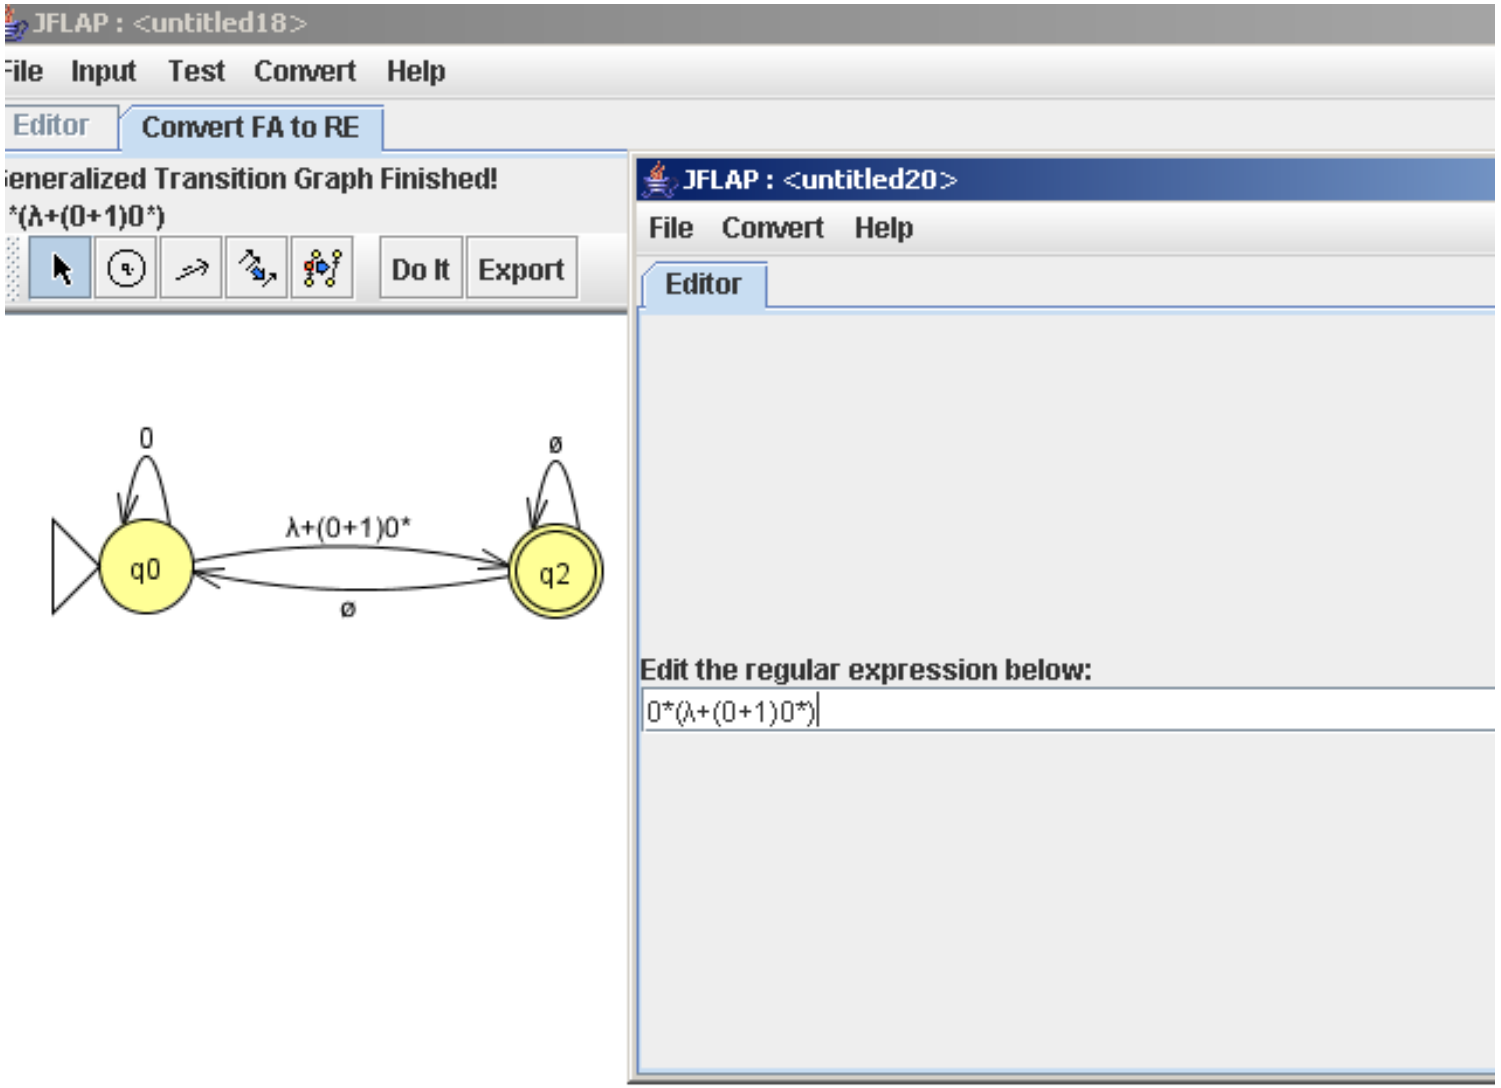
JFLAP : <untitled18>
File Input Test Convert Help
Editor
Convert FA to RE
eneralized Transition Graph Finished!
(λ+(0+1)0)
Do It
Export
0
ø
λ+(0+1)0*
q0
q2
ø
JFLAP : <untitled20>
File Convert Help
Editor
Edit the regular expression below:
0*(λ+(0+1)0*)

Conversão de AF para ER no JFLAP

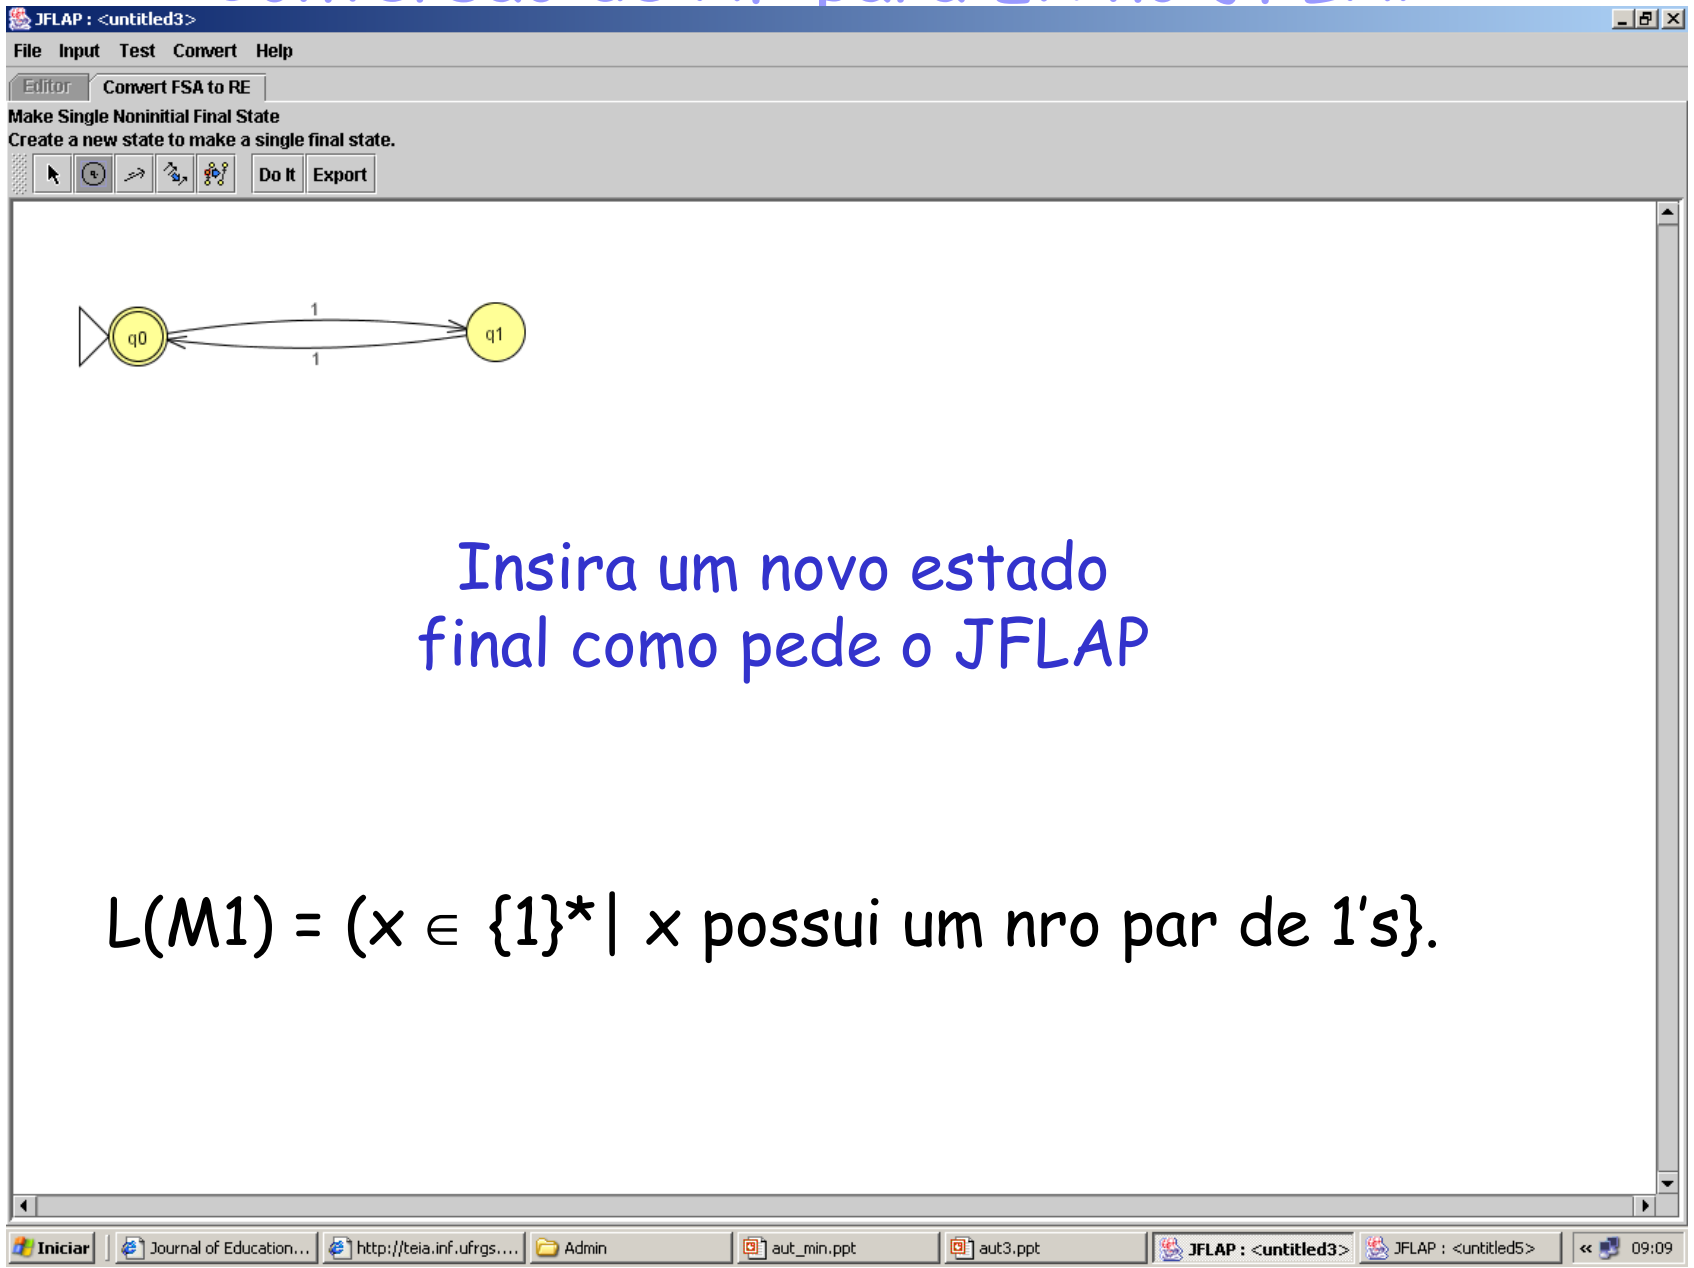

Insira um novo estado
final como pede o JFLAP

L(M1) = (x ∈ {1}* | x possui um nro par de 1's}.

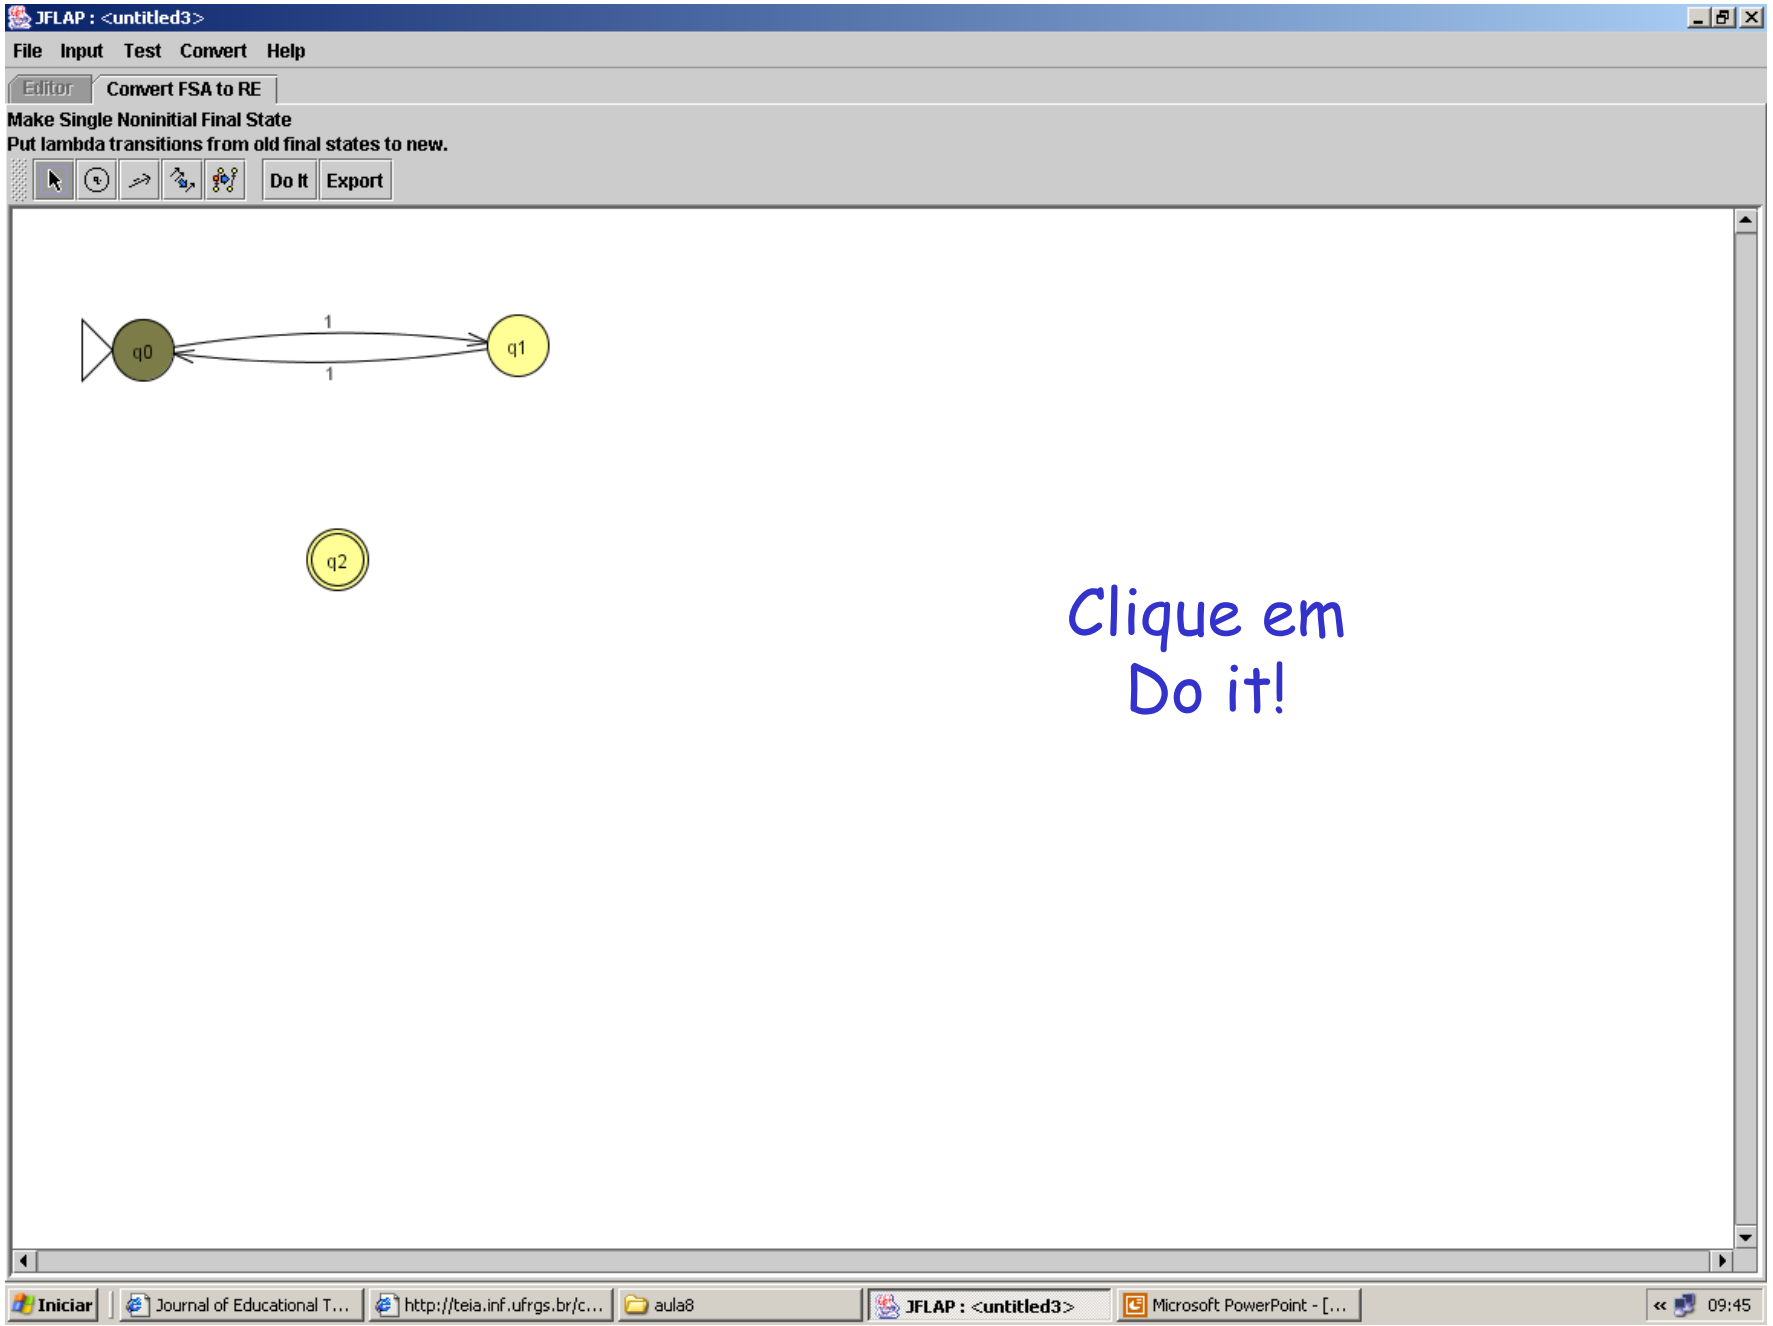
JFLAP : <untitled3>
File Input Test Convert Help
Editor Convert FSA to RE
Make Single Noninitial Final State
Put lambda transitions from old final states to new.
Do It Export
q0
q1
q2
1
1
Clique em
Do it!
Iniciar
Journal of Educational T...
http://teia.inf.ufrgs.br/c...
aula8
JFLAP : <untitled3>
Microsoft PowerPoint - [...
09:45

Coloque transições nulas nos estados sem transição

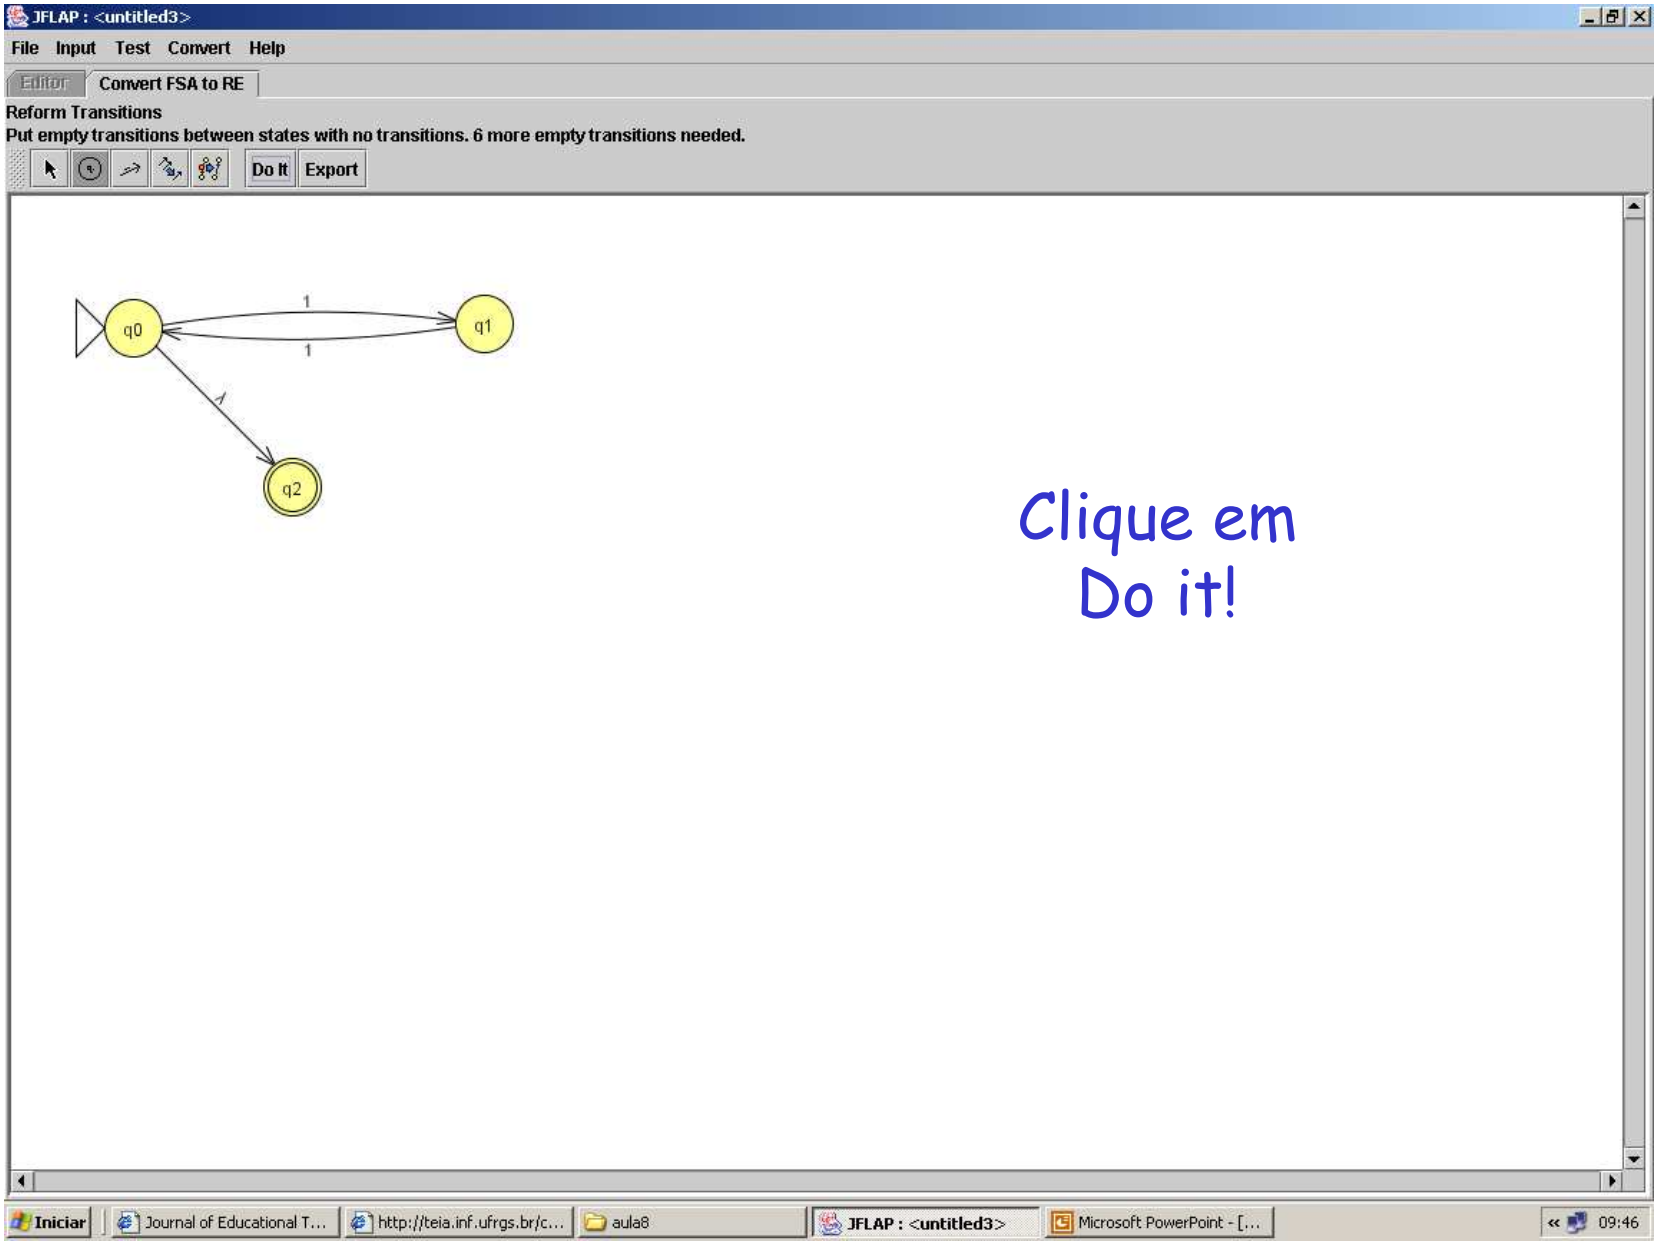

Clique em
Do it!

Completa as 6 transições faltantes

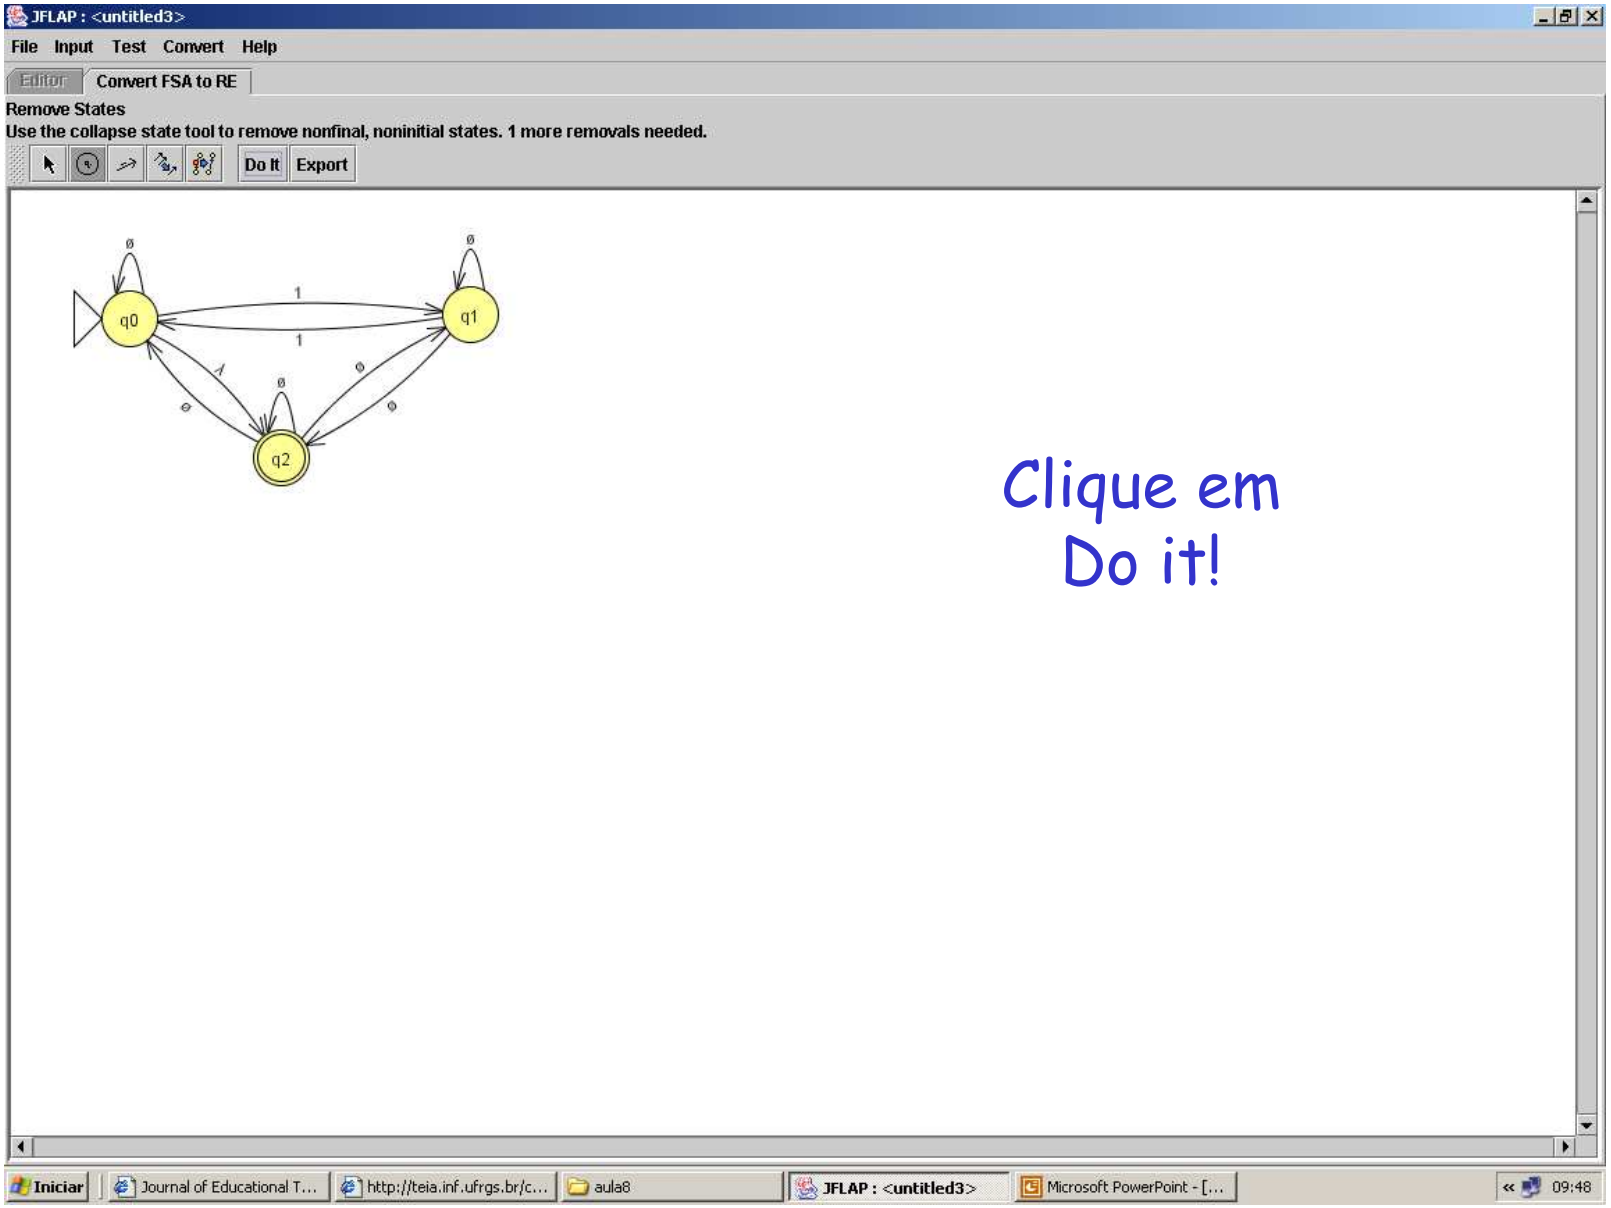

Grafo terminado

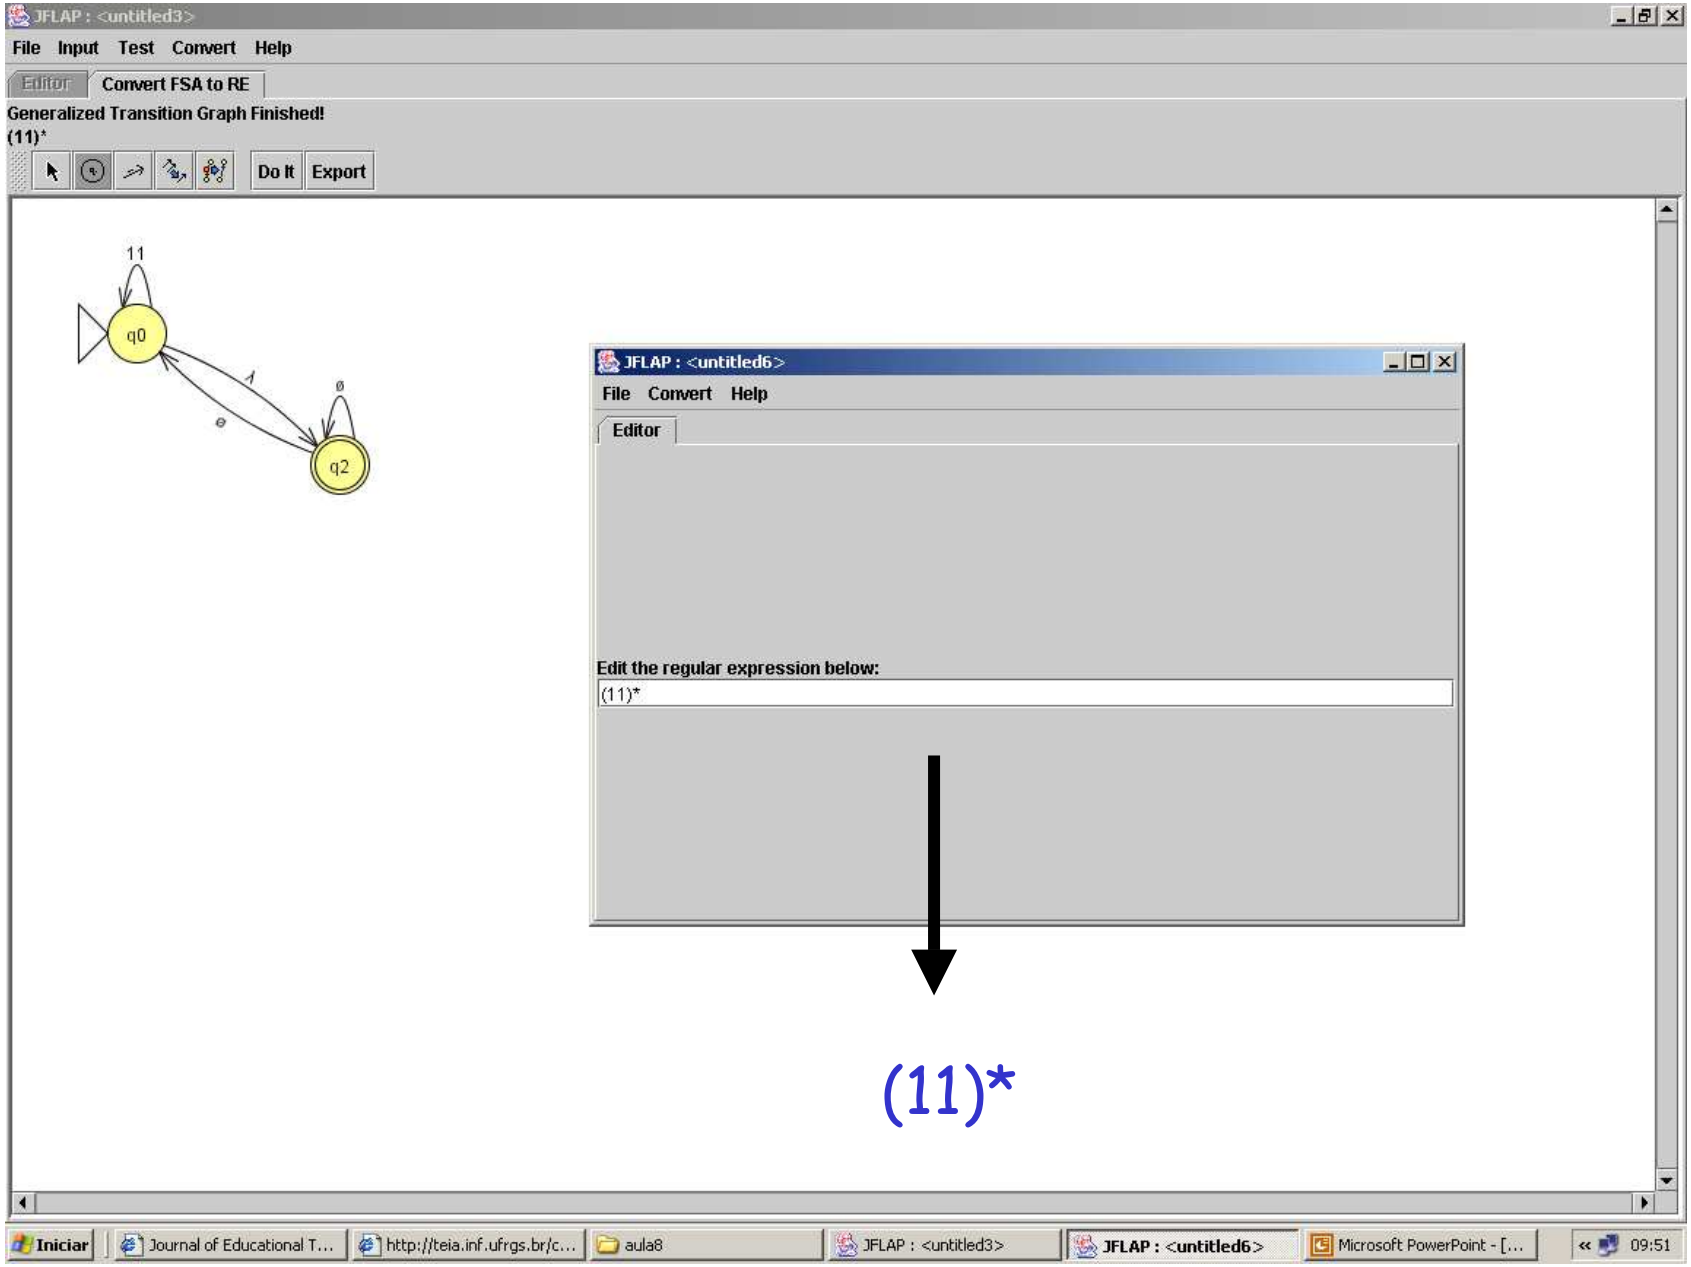

Propriedades algébricas das ER

- L + M = M + L (união é comutativa)
- (L + M) + N = L + (M + N) (união é associativa)
- (LM)N = L(MN) (concatenação é associativa)
- Exercício: a concatenação é comutativa???

- $\emptyset$ + L = L + $\emptyset$ = L ($\emptyset$ é o elemento nulo para união)
- λL = Lλ = L (λ é o elemento nulo para concatenação)
- $\emptyset$L = L$\emptyset$ = $\emptyset$

- $L(M + N) = LM + LN$ (lei distributiva à esq)
- $(M + N)L = ML + NL$ (lei distributiva à dir)

- $L + L = L$

- $(L^*)^* = L^*$
- $\emptyset^* = \lambda$
- $\lambda^* = \lambda$

- Algumas extensões de LR usadas em utilitários do UNIX

- $L^+ = LL^*$
- $L? = (L + \lambda)$ (usado no Lex para indicar opcional)

Exercícios

- Faça ER para:
- identificadores
- números reais com sinais
- Inteiros com sinais
- cadeias de caracteres (imprimíveis)
- e comentários do Pascal.

- reais do Fortran (.5 e 5. além dos padrões de reais de Pascal)

Sobre Non-Printable Characters (1)

http://www.regular-expressions.info/characters.html

- You can use special character sequences to put non-printable characters in your regular expression.
- Use \t to match a tab character (ASCII 0x09), \r for carriage return (0x0D) and \n for line feed (0x0A).
- More exotic non-printables are \a (bell, 0x07), \e (escape, 0x1B), \f (form feed, 0x0C) and \v (vertical tab, 0x0B).
- Remember that Windows text files use \r\n to terminate lines, while UNIX text files use \n.

Sobre Non-Printable Characters (2)

- You can include any character in your regular expression if you know its hexadecimal ASCII or ANSI code for the character set that you are working with.
- In the Latin-1 character set, the copyright symbol is character 0xA9.
- So to search for the copyright symbol, you can use \xA9.
- Another way to search for a tab is to use \x09. Note that the leading zero is required.

Sobre Non-Printable Characters (3)

- Most regex flavors also support the tokens \cA through \cZ to insert ASCII control characters.
- The letter after the backslash is always a lowercase c.
- The second letter is an uppercase letter A through Z, to indicate Control+A through Control+Z.
- These are equivalent to \x01 through \x1A (26 decimal).
- E.g. \cM matches a carriage return, just like \r and \x0D.
- In XML Schema regular expressions, \c is a shorthand character class that matches any character allowed in an XML name.
- If your regular expression engine supports Unicode, use \uFFFF rather than \xFF to insert a Unicode character.
- The euro currency sign occupies code point 0x20AC. If you cannot type it on your keyboard, you can insert it into a regular expression with \u20AC.

- Pascal, com L = {a..z,A..Z}; D = {0..9}
- ID: (L|_)(L|D|_)*

- Reais: (+|-|λ) (D+ . D+ (E (+|-|λ) D^+ | λ) |
  D^+ (. D^+ | λ) E (+|-|λ) D^+)

- Observem que acima exigimos que o real tenha uma parte com ponto fixo ou com ponto flutuante, mas a linguagem pode não exigir e o seu real mínimo seria um inteiro:
- [+|-] D+ [.D+] [E [+|-] D+]

- Inteiros: (+|-|λ) D^+ = [+|-] D+
- Cadeias: ´ C* ´ onde C é ASCII menos ´

(com essa limitação não tratamos os acentos na moda antiga do Pascal para não perder expressividade)

Comentários em Pascal

- { C* }
- onde C é ASCII menos }

- /* C* * (* + EC* *)* /

- onde C é ASCII menos * e E é ASCII menos / e *
- A solução acima vem do AF para comentários (próximo slide)

AF que reconhece comentários da forma /* ... */

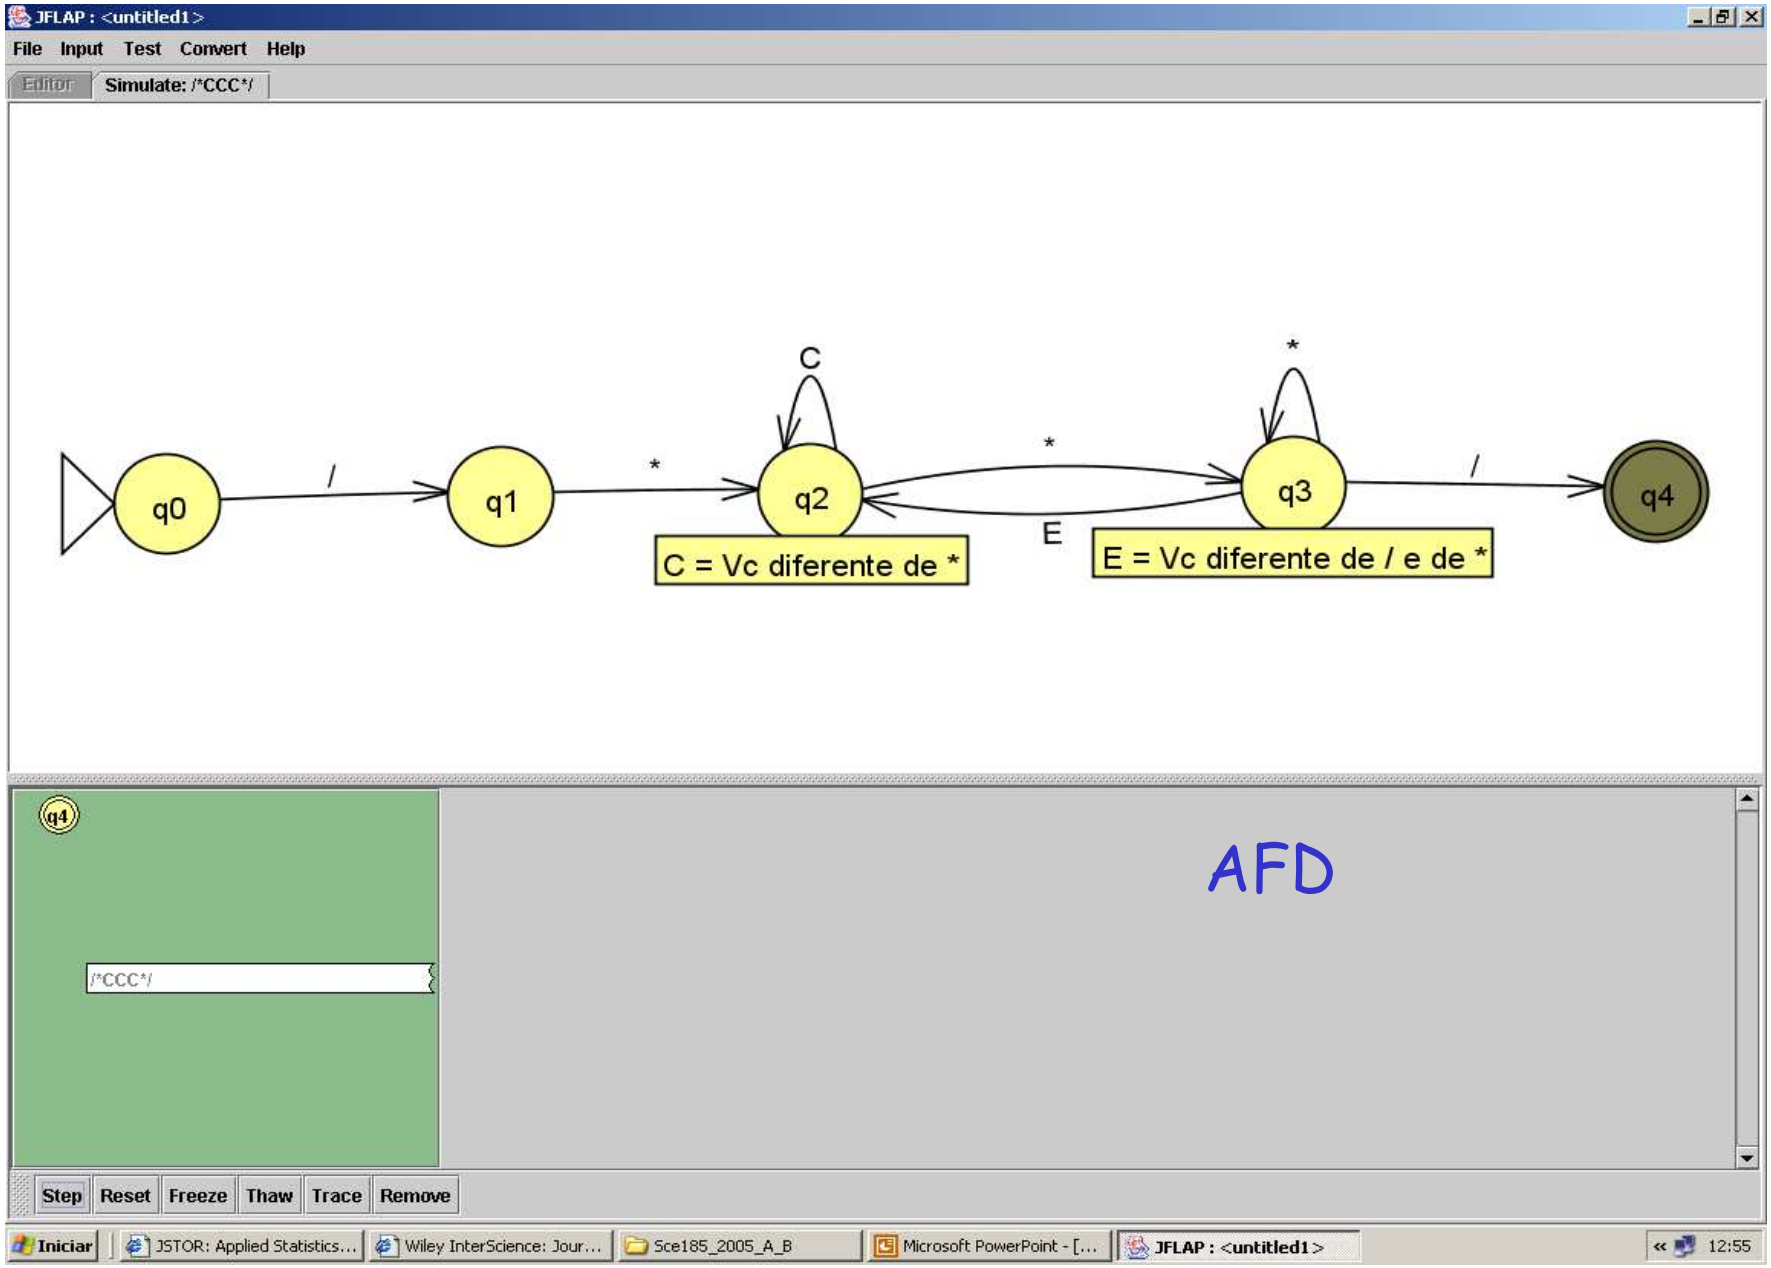

/* C* * (* + EC* *)* /

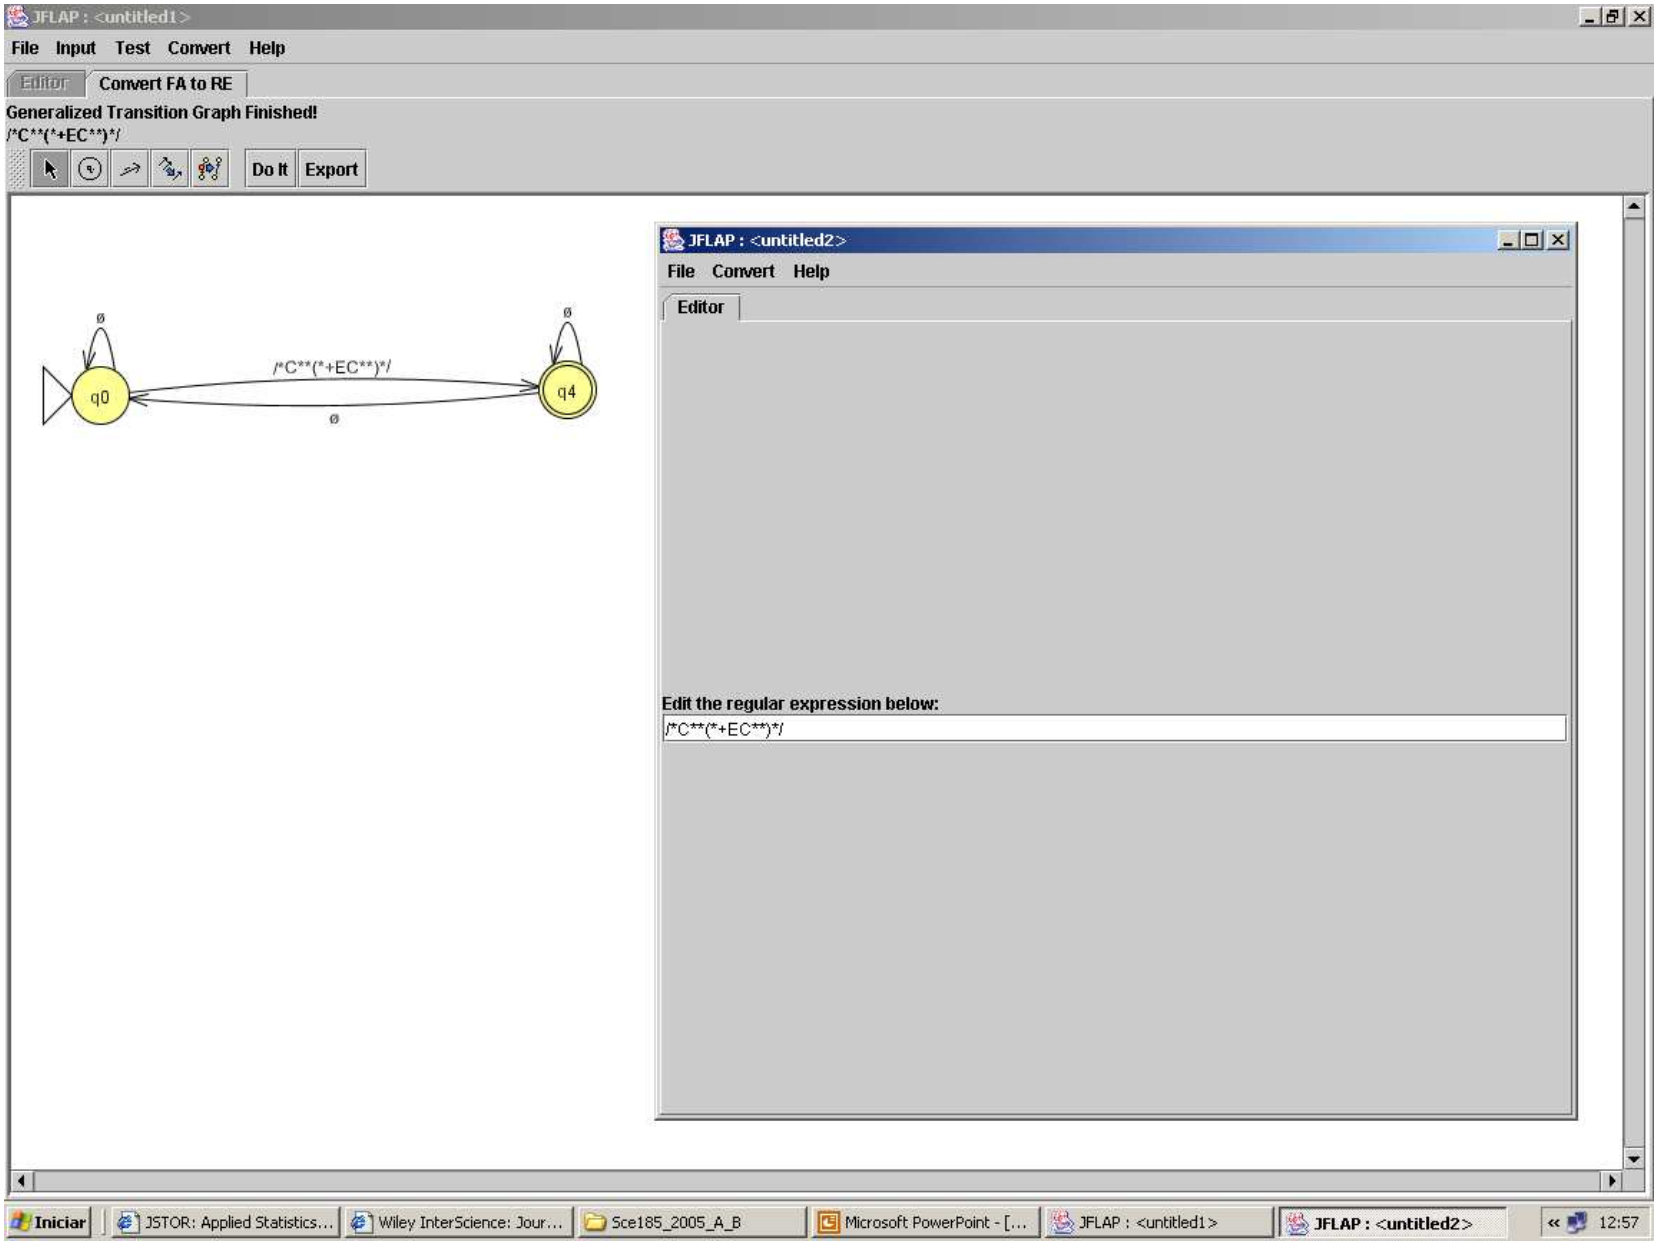
JFLAP : <untitled1>
File Input Test Convert Help
Editor
Convert FA to RE
Generalized Transition Graph Finished!
/*C**(*+EC**)*/
Do It
Export
ø
/*C**(*+EC**)*/
q0
q4
ø
JFLAP : <untitled2>
File Convert Help
Editor
Edit the regular expression below:
/*C**(*+EC**)*/
Iniciar
JSTOR: Applied Statistics...
Wiley InterScience: Jour...
Sce185_2005_A_B
Microsoft PowerPoint - [...
JFLAP : <untitled1>
JFLAP : <untitled2>
12:57

Reais Fortran

- (+|-|λ) (D^+. | .D^+ | D^+ . D^+) (E (+|-|λ) D^+ | λ)
- Ou
- [+|-] (D^+. | .D^+ | D^+ . D^+) [E [+|-] D+]

Equivalências entre AFD, AFND, AF-λ, ER, GR

Trivial2: decorre da definição

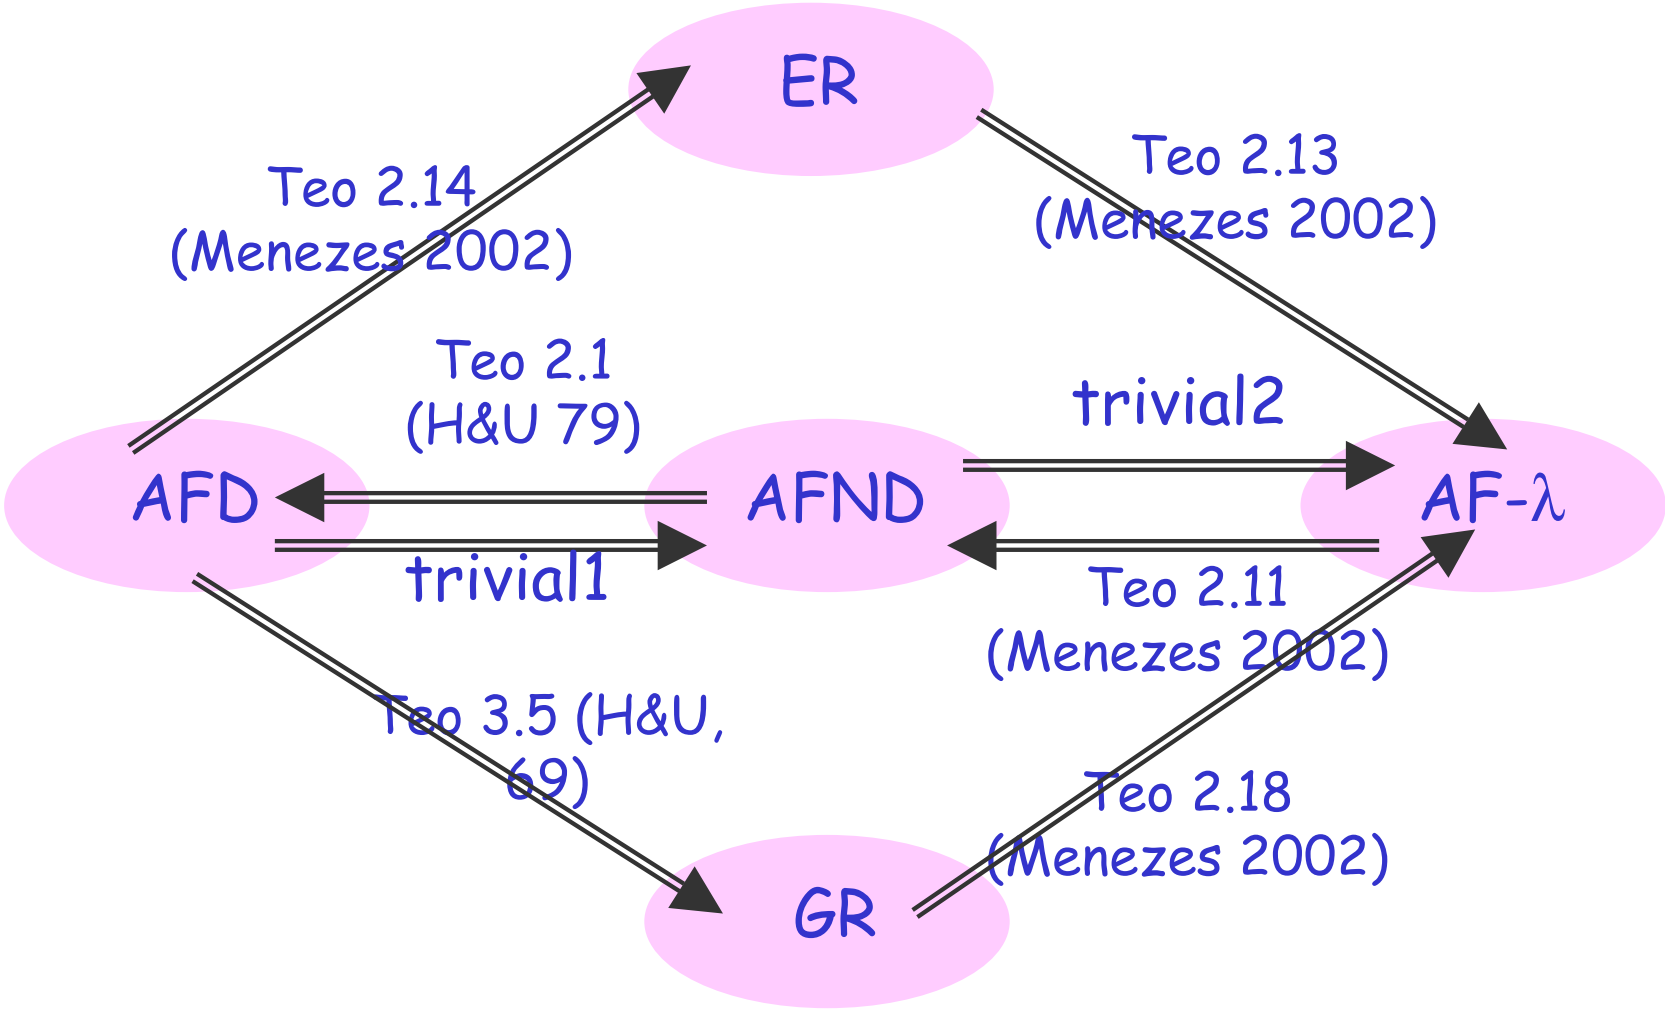

Trivial1: colocar { } nos estados