doi:10.3969/j.issn.1000-436x.2013.10.021

基于状态约束的大规模正则表达式匹配算法

贺炜，郭云飞，扈红超
（国家数字交换系统工程技术研究中心，河南 郑州 450002）

摘 要：通过观察不确定有限自动机 NFA 到确定性有限自动机 DFA 的转化过程，分析内存增长的原因，提出了一种基于状态间约束关系的正则表达式匹配算法 Group^2-DFA。Group^2-DFA 通过两级分组，利用状态间的约束关系，将原始 NFA 转化为 NFA 和 DFA 的混合结构。实验表明，在保持一定处理速率的前提下，Group^2-DFA 能够有效地减少内存占用。在 300 条规则下，Group^2-DFA 吞吐率能够达到 1Gbps，并且减少约 75%的状态数。
关键词：正则表达式；状态爆炸；自动机转化；状态约束
中图分类号：TP 393 **文献标识码**：A **文章编号**：1000-436X(2013)10-0183-08

States constrain-based algorithm for large scale regular expression matching

HE Wei, GUO Yun-fei, HU Hong-chao
(National Digital Switching System Engineering Technological R&D Center, Zhengzhou 450002, China)

Abstract: By analysis of state explosion in deterministic finite automata DFA, a novel algorithm Group^2-DFA based on state constrains was proposed to reduce the memory usage. With the state constrains, states in NFA were classified into several groups. Group^2-DFA introduces two-level classification and merges NFA and DFA together to a hybrid FA construction. The experiments show that Group^2-DFA can reduce memory usage efficiently and keep high throughput with a small increase of memory reading time. With 300 regex rules, Group^2-DFA can cut 75% states and achieve 1Gbps throughput.
Key words: regular expression; state explosion; automata convert; state constrains

1 引言

近年来，作为网络信息过滤、文字处理等应用中的关键组成部分，正则表达式匹配技术得到了快速发展。正则表达式匹配技术作为实现大规模模式匹配的主要手段，广泛应用于二进制序列分析、扩展标记语言处理及入侵检测系统中[1,2]。目前正则表达式匹配主要通过不确定性有限自动机（NFA, nondeterministic finite automata）以及确定性有限自动机（DFA, deterministic finite automata）来实现。

假设需要对 k（$k>1$）条正则表达式完成匹配，其中，第 i（$i=1,2,\cdots,k$）条正则表达式中包含 n_i 个字符。将 k 条正则表达式通过 McNaughton-Yamada 构造法转化为 NFA 后，会产生 $n=\sum_{i=1}^{k} n_i$ 个 NFA 状态[3]，每输入一个字符，都需要对这些状态进行并行检测。上述特性导致基于 NFA 的正则表达式匹配在处理过程中的时间复杂度较高。虽然 NFA 能够通过硬件结构的加速来提高处理速率，但硬件加速方案通常缺少灵活性并且很难做到实时更新[4]。

针对 NFA 的缺点，另外一种解决方案是将 NFA 转化为 DFA。通过将 NFA 中各个状态之间所有的有效转移存储在状态转移表（STT, state transition table）中，DFA 可在硬件或软件平台中得到较好的实现。但是，基于 DFA 的正则表达式匹配也存在一些问题[5]。

收稿日期：2012-07-15；**修回日期**：2013-04-15
基金项目：国家科技支撑计划基金资助项目（2012BAH02B03, 2012BAH02B01）；国家高技术研究发展计划（“863”计划）基金资助项目（2011AA01A103，2011AA01A101，2011BAH19B04）
Foundation Items: The National Science & Technology Pillar Program (2012BAH02B03, 2012BAH02B01); The National High Technology Research and Development Program of China (863 Program)(2011AA01A103, 2011AA01A101, 2011BAH19B04)

1) 状态数爆炸：在最坏情况下，对于有 n 个状态的 NFA，其最小等价 DFA 的状态数将达到 $O(2^n)$ 数量级。

2) 压缩时间代价：尽管 STT 可以通过消除相似状态冗余来压缩，但是现有压缩算法的时间复杂度至少为 $O(n^2)$。

NFA 的空间特性较好，时间特性较差，而 DFA 相反，两者都不能很好地满足实际网络应用的需求。因此，快速高效是大规模正则表达式匹配的首要目标。本文将 NFA、DFA 两者优势相结合，提出了一种新的自动机构建算法 Group^2-DFA，在保持高速处理的前提下，缓解 DFA 状态爆炸的影响。本文首先通过分析状态爆炸现象，得出 DFA 状态爆炸的原因；然后根据状态间约束关系对 NFA 状态集合进行分组；第三步将每个 NFA 组转化为 DFA，得到若干 single-DFA，将各个 single-DFA 按照一定的方法组合，得到 Group-DFA。由于 Group-DFA 处理速率较低，对 Group-DFA 进行二级分组，最终得到 Group^2-DFA。

2 相关工作

基于 NFA 的正则表达式匹配最初在集成电路中实现，随后 SIDHU 和 PRASANNA 将其部署在现场可编程门阵列（FPGA）中[6]。为了进一步提高系统的吞吐率以及资源利用率，FPGA 实现中加入了许多优化措施，例如流水线、前缀提取、多字符匹配、字符编码等[7,8]。但是由于电路结构本身的缺点，在 FPGA 平台中，很难对基于 NFA 的正则表达式匹配进行及时更新。

基于 DFA 的正则表达式匹配可通过处理器架构来实现，相对于 NFA，这种结构更加简单并易于操作。然而，状态爆炸问题导致算法对于内存的需求急剧增加，影响了内存性能和实际中部署的可行性。

为了解决 DFA 内存需求高的问题，目前常用的方法有 2 种：1）YU、PASETTO 等[9,10]利用 NFA 的不确定性来压缩 STT，以此达到较高的吞吐率性能。但是这类方法计算的复杂度较高，且大多依赖于特定的正则表达式集合特性。QI 等[11]利用 DFA 状态的相似性压缩 STT，提出 FEACAN（front-end acceleration for content-aware network）算法，能够达到 80%的压缩率。LIU 等[12]提出的 CSCA（cluster-based splitting compression algorithm）通过切分 STT 发现内在的冗余，能够达到 95%的压缩率。但是 FEACAN 和 CSCA 算法都会降低系统的吞吐率。2）将大规模正则表达式匹配问题分解为若干小问题分别解决。ANTONELLO 等[13]使用判决检验算法将 $m(m>1)$ 个正则表达式组合成 $g(m>g>0)$ 个小组；WOODS 等[14]将正则表达式切分为前缀和后缀 2 个组合，并且将所有的前缀构造为一个复合 DFA，当到达 DFA 边界状态时，触发后缀匹配；YANG 等[15]提出的 SFA（semi-deterministic finite automata）算法采用 NFA 和 DFA 混合结构，在空间利用和吞吐率方面均有较好的效果。

3 理论基础

3.1 正则表达式匹配

定义 1 对于正则表达式 R，基于 NFA 的正则表达式匹配是在连续输入字符流的条件下，构造不确定性有限自动机 $M=(Q,\Sigma,\delta,q_0,F)$，其中，$Q$ 是有限的 NFA 状态集合；Σ 是有限的字母表；δ 是不确定性状态转移函数，数量级为 $Q\times\Sigma$，大约为 2^Q；q_0 是状态机的初始状态，$q_0\in Q$；F 是状态机结束状态集合，$F\subseteq Q$。

定义 2 对于正则表达式 R，基于 DFA 的正则表达式匹配是根据标准构造方法，将相应的不确定性有限自动机 M 转化为确定性有限自动机 $M'=(Q',\Sigma,\delta',q_0,F')$，其中，$Q'$ 是有限的 NFA 状态集合，$Q'\subseteq 2^Q$；δ' 是确定性状态转移函数，数量级为 $Q\times\Sigma$；F' 是状态机结束状态集合，$F'\subseteq Q'$；q_0 和 Σ 的定义与 NFA 中相同。

3.2 状态爆炸分析

YU 等[9]证明了对于实际的正则表达式，NFA 到 DFA 的转化会引起指数级别的状态爆炸，其等价最小 DFA 有 2^n 个状态。为了更好地说明 Group^2-DFA 原理，简要分析发生状态爆炸的原因。

对于正则表达式 $r_1=/.*[a|b][c|d]\{n-1\}/.$，构建 NFA，命名为 A。A 中有初始状态 q_0、结束状态 q_n 及 $n-1$ 个中间状态 $\{q_1,\cdots,q_{n-1}\}$，各个状态间相互独立，互不影响。接收任意的输入，q_0 到达状态 q_1；接收输入 a 或 b，q_1 到达状态 q_2；接收输入 c 或 d，q_i 到达状态 q_{i+1}，$1<i<n$。

构造输入字符流，第一个字符为任意字符，第二个字符为 a 或 b，之后的字符为 c 或 d，各个字符之间相互独立不相关。当正则表达式 r_1 接收到这一字符流时，对应的 2^n 个状态均可能出现。将 A

转化为 DFA 后，至少会有 2^n 个状态，与原有 $n+1$ 个状态相比，呈指数级增长。

以上论述的基础是各个输入字符间相互独立，各个状态间互不影响，而在实际应用中，各个状态间存在相互约束，利用这种约束关系，可减小状态爆炸的规模。例如：状态 q_1、q_2 相互独立时，状态间约束不确定，存在 4 种状态组合 $(q_1,q_2)=\{(0,0),(0,1),(1,0),(1,1)\}$（标记 1 表示状态被激活）。若假设状态 q_1 被激活时，q_2 一定被激活，则状态间约束关系确定，状态组合变为 $(q_1,q_2)=\{(0,0),(1,1)\}$ 2 种，转化为 DFA 后，总状态数由 2^{n+1} 减少为 2^n。以此类推，当各个状态间均有确定的约束关系时，可消除 DFA 状态爆炸的现象。

3.3　状态约束关系

根据状态爆炸分析可得出，若能确定状态间的约束关系，减少转化过程中的不确定性，则可大幅地减少 DFA 中的状态数。为描述状态间约束关系，引入 3 种集合关系：相交、包含、分离，具体定义如下。

定义 3　记 $(q_0,s)=q$，其中，s 为输入序列字符串；q_0 为初始状态，q 为 q_0 接收输入 s 后到达的目的状态。状态 $q_x,q_y\in Q$，记 Φ_x 是满足 $(q_0,s)=q_x$ 的输入序列 s 的集合，Φ_y 是满足 $(q_0,s)=q_y$ 的输入序列 s 的集合。

若 $\Phi_x\cap\Phi_y=\phi$，则 q_x,q_y 互相分离，记为 $q_x\cap q_y=\phi$。

若 $\Phi_x\cap\Phi_y=\Phi_x$，则 q_x 包含于 q_y，记为 $q_x\subseteq q_y$。

若 $\Phi_x\cap\Phi_y\neq\phi$ 且 $\Phi_x\not\subset\Phi_y,\Phi_y\not\subset\Phi_x$，则 q_x,q_y 相交。

当 q_x,q_y 分离时，约束关系确定，q_x,q_y 不会被同时激活，在转化为 DFA 的过程中，不会引起状态爆炸。

当 q_x 包含于 q_y 时，q_x 被激活，q_y 一定被激活，不会引起状态增加；当 q_y 被激活，q_x 不一定被激活，会引起一定的状态数增长。

当 q_x,q_y 相交时，2 种状态相关性不强，可能同时被激活，也可能只激活一个，约束关系不确定，会引起状态爆炸。

根据定义的 3 种约束关系，提出 NFA 状态约束关系分析（NFA-SCA, NFA state constrain analysis）算法，可得到 NFA 状态集中任意 2 个状态之间的约束关系。图 1 中 1）~8）通过分析状态转移路径，得到各个状态对应的输入序列集合 Φ；9）~15）比较各个状态的输入序列集合，决定相互间约束关系的种类。NFA-SCA 算法伪代码描述如图 1 所示。

```
输入：NFA M=(Q,Σ,δ,q0,F)， qx,qy∈Q/q0
输出：状态间约束关系
1)  for qi∈Q,qi≠q0//遍历NFA状态集中状态
2)    for sij⊂Σ* //遍历相应的输入字符串
3)      //记录由q0到达状态qi的j种字符串sij
4)      remember (sij,qi)
5)      //合并对应的j条字符串
6)      Φi=Φi∪sij
7)    end for
8)  end for
9)  for qx,qy∈Q;qx≠qy
10) //对任意2个状态，得到状态间的约束关系
11)   if    Φx∩Φy=∅   then (qx,qy)=0
12)   else if Φx∩Φy=Φx  then (qx,qy)=1
13)   else if Φx∩Φy=Φy  then (qx,qy)=2
14)   else                (qx,qy)=3
15) end for
```

图 1　NFA-SCA 算法

4　基于状态约束的 Group^2-DFA 算法

4.1　NFA 状态集合分组

为了降低状态数爆炸式增长对正则表达式匹配的影响，在 NFA-SCA 算法得到的状态间约束关系的基础上，按照以下原则将状态集合划分为若干小组：

1) 同一组内状态两两不相交；

2) 相交的状态放到不同的组内；

3) 每个组内包含尽可能多的相离和相互包含的状态。

依照上述原则分组可保证同一组内不会有相交状态，确定了状态间的约束关系，避免了大规模的状态增长。

划分过程步骤如下。

1) 初始化：建立状态集合 V，包括所有 NFA 状态，置 $m=0$。

2) 若 V 不为空，建立空集合 V_m。按状态序号，取 V 中一个状态 q_t，作以下判断：

①若 V_m 为空，q_t 加入 V_m，并从 V 中删除 q_t；

②若 V_m 不为空，将 q_t 与 V_m 中所有状态相比，若 q_t 与这些状态都不相交，则 q_t 加入 V_m，并从 V 中删除 q_t；否则，q_t 放回 V 中，尝试 V 中下一个状态，

直到遍历 V 中的所有状态。记录 V_m 及其大小，$m = m + 1$。重复 2）直到 V 为空。

状态集合划分（SSD, state set division）算法的伪代码描述如图 2 所示。

```
输入：NFA 状态集合
输出：k 个分组集合
1) while V ≠ ∅
2)     create V_m=∅
3)     for all q_i ∈ V
4)         if V_m=∅ or (V_m, q_i) = 0/1/2
5)         then V_m = V_m ∪ q_i; V=V−q_i
6)     end for
7)     m = m + 1;
8) end while
```

图 2 SSD 算法

4.2 构建一级分组 DFA(Group-DFA)

SSD 算法可得到 k 个状态集合 $V_m, m = 0,1,\cdots,k$，每个 V_m 均有自身对应的状态集、字符表、转移函数、初始状态、结束状态，即对应于一个 NFA，$M_m = (Q_m, \Sigma, \delta_m, q_{0m}, F_m)$，其中，$Q_m$ 是 V_m 中的状态集合；Σ 是有限的字母表；δ_m 是 V_m 中的状态转移函数；q_{0m} 是 NFA 的初始状态；F_m 是 NFA 结束状态集合；

对于每一个 M_m，按照标准构建算法转化为相应的等价 DFA，即为 M_m'，由于每个 M_m 中不包含相交的状态，所有每个 M_m' 中状态数增长较少。这样可得到 k 个独立的 DFA，称为 k 个 single-DFA。

每个 single-DFA 中包括 2 种状态转移：内部转移和平行转移。内部转移实现 DFA 内部的状态跳转，每个平行转移作为其他 single-DFA 的输入，激活另一个 single-DFA 中的状态；因此，single-DFA 中的若干个状态都有可能同时被内部转移和其他 single-DFA 的平行转移同时激活，这种情况不满足 DFA 同一时刻只有一个激活状态的特性，为保证 DFA 的特性，添加多跳转关系综合判断逻辑，保留一个激活状态。

多跳转关系综合判断（MTA，multi-transition analysis）：按照 single-DFA 编号的大小，即 m 值的大小定义优先级：m 值越小，single-DFA 输出的平行转移的优先级越高。当一个 single-DFA 中的几个状态同时被激活时，选择优先级高的转移所激活的状态，其余状态不被激活。

构造 Group-DFA 时，每个 single-$DFA(i)$ 最多有 k 个进位输出状态，以 k bit 长进位输出向量 *vector* 记录该输出状态。k 个 single-DFA 最多同时有 k 个进位输出向量：$\boldsymbol{vector}(1),\cdots,\boldsymbol{vector}(k)$，记录此 k 个向量值，共需要 $k \times k$ 大小的矩阵存储。

对于 k 个向量值，分析每个 single-DFA 会接收哪些平行转移，通过判断这些进位输出的优先级，即源 DFA 序号，确定保留哪一个平行转移作为输入。

MAT 算法代码描述如图 3 所示。

```
输入：k 个 single-DFA 输出的所有平行转移
输出：k 个 single-DFA 所需输入的平行转移
1)  for  i = 1 : k
2)      for  j = 1 : k      //vector(1) : vector(k)
3)      //选择vector值最小的作为跳转输入
4)          if  vector(j, i) = 1
5)              output(j, i);  continue;
6)      end for
7)  end for
```

图 3 MTA 算法

k 个 single-DFA 间采用多跳转关系综合判断逻辑连接，都满足 DFA 的特性，组成的新 DFA 结构命名为 Group-DFA。Group-DFA 是 NFA 与 DFA 的混合结构，其中，各个 DFA 单独运行，DFA 之间为并行操作，由同一个初始状态触发，相当于 NFA 中的各个状态，呈现 NFA 特性。

在最好的情况下，原始 NFA 中，各个状态都不相交，则构造的 Group-DFA 是一个单独的 DFA；在最坏的情况下，各个状态相互之间都相交，则构造的 Group-DFA 仍然是原始的 NFA。

4.3 构建二级分组 DFA(Group^2-DFA)

Group-DFA 算法在实现过程中没有限制分组的数目。对于有 N 个状态的 NFA，假设存在 k 个相交状态对，则会产生 k 个 single-DFA。由于 k 个 single-DFA 之间呈 NFA 特性，k 值过大将导致处理速率急剧降低。

为降低分组数量对处理速率的影响，设计二级分组结构如下。

1) 将 k 个 single-DFA 看作一个 NFA 中的 k 个状态。

2) 对该 k 个状态执行 NFA-SCA 算法，得到状态间约束关系。

3) 根据 2）中的结果，执行 SSD 算法，对状态集合进行划分，得到二级分组集合。不同之处在于划分集合的数目限定为 p 个，若存在多于 p 个的相交状态，将多余的状态划入已知的 p 个集合中，得到二级分组集合。

4) 对 3）中得到的 p 个 NFA 状态集合按照标

准构建算法转化为 p 个 DFA，称为 Class2-DFA；并执行 MTA 算法，将 p 个 Class2-DFA 通过多跳转关系综合判断逻辑连接。

5) 在 4）的结果中加入初始状态，二级分组 DFA——Group^2-DFA 构建结束，Group^2-DFA 中包含 p 个 Class2-DFA 结构， Class2-DFA 中的每个状态对应一个 single-DFA。

Group^2-DFA 中包含 3 种转移关系：Class2-DFA 的内部转移、Class2-DFA 之间的平行转移和 single-DFA 的内部转移。Group^2-DFA 中同样存在多个 DFA 状态被同时激活的问题，按照 single-DFA 中的方式，根据编号大小来定义优先级，然后使用多跳转关系综合判断逻辑处理。

4.4　性能分析

有 n 个状态的 NFA，时间复杂度为 $O(1)$，空间复杂度为 $O(n)$；构建 Group-DFA 后，有 k 个 single-DFA，时间复杂度为 $O(k^2)$，空间复杂度为 $O(an)$，其中，a 为线性常数；构建 Group^2-DFA 后，等价 NFA 结构有 p 个状态，且有两级的 DFA 逻辑结构，所以时间复杂度为 $O(2p^2)$，在 p 个二级集合中，每个集合最坏情况下有$\lceil k/p \rceil$个相交状态，每一个状态代表一个 single-DFA，定义 $x=\lceil k/p \rceil$ 为二级分割参数；将 p 个二级集合转化为 p 个 DFA 后，相比于 Group-DFA，状态数会增加 $(2^x/x)$ 倍，空间复杂度为 $O((2^x/x)an)$，随着$\lceil k/p \rceil$值的增加，Group^2-DFA 的空间复杂度增大，但时间复杂度减小，为了权衡时间和空间的代价，p 值的选取需要根据实验结果和实际需求来确定。

5　实验仿真和性能验证

5.1　模型建立

针对 Group-DFA 中 NFA、DFA 混合的特点，设计处理模型如图 4 所示。

图 4 中，Group-DFA 由若干个 single-DFA 单元以及多跳转关系综合判断模块（简称为综合模块）组成，single-DFA 单元如虚线框内所示，包括状态查找表 STT、状态合并、输入组合 3 个模块：输入组合以输入字符和当前状态作为输入，并将组合结果送入 STT 查询；STT 根据输入数据得到相应的转移结果，若是内部转移，直接送入状态合并模块，若是进位转移，则送入综合模块；状态合并模块接收 STT 的内部转移以及综合模块得到的进位转移作为输入，决定在 single-DFA 内部选择哪一个转移状态作为当前状态。

综合模块实现 MTA 算法中的功能，分析处理各个 single-DFA 得到的进位转移结果。

对于 Group^2-DFA，二级分组结构包含 p 个 DFA 结构，每个 DFA 中的状态对应一个 single-DFA，处理模型如图 5 所示。

5.2　性能仿真

性能分析采用的实验环境为：系统：Ubuntu 11.10；编译环境：gcc4.2.4；内存：2 GB；CPU：Intel 双核。

实验数据采用 snort24、snort31、bro217、dotstar300 等 4 个规则集[16,17]。本节从空间存储消耗、系统吞吐率以及单字符平均内存访问次数 3 方面对算法性能进行分析，对比算法包括 Group^2-DFA 算法、SFA 算法、FEACAN 算法以及 CSCA 算法。为了评价 4 种算法的性能，消除额外因素的影响，算法实现时，去掉了 FEACAN 算法中的硬件加速部分。

5.2.1　正则表达式规模与 single-DFA 数量关系

表 1 中给出了正则表达式规模与生成的 single-DFA 数量之间的关系，规模大小以正则表达式数量表示；采用 NFA-SCA 算法和 SSD 算法生成相应的若干 single-DFA。

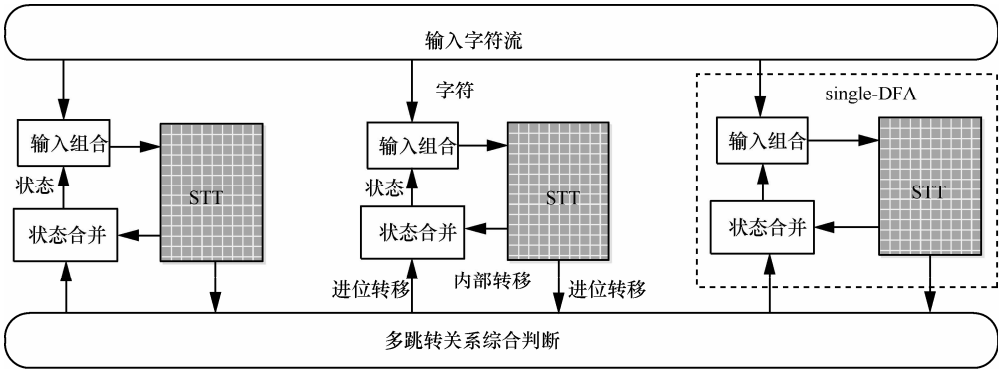

图 4　Group-DFA 处理模型

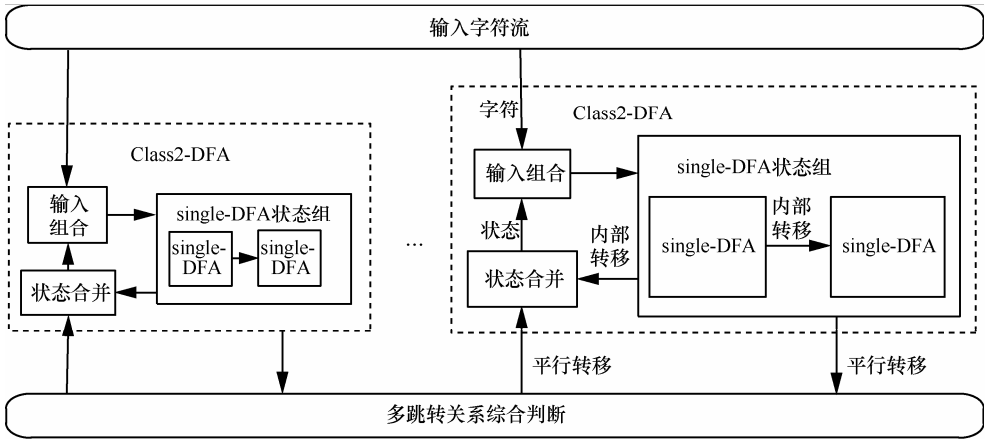

图 5　Group^2-DFA 处理模型

表 1　正则表达式规模与 single-DFA 数量关系

正则表达式数目	NFA 状态数	single-DFA 数量
16	418	15
20	524	18
24	571	21
34	882	33
217	2 130	59
300	11 145	133

从表 1 中可看出，随着正则表达式规模的增大，NFA 状态数也增多，各个状态之间的关系也更加复杂，出现了更多的相交情形，single-DFA 的数量也随之增多。

5.2.2　二级分割参数$\lceil k/p \rceil$的选取

为衡量二级分割参数 $x=\lceil k/p \rceil$ 对 Group^2-DFA 状态数和吞吐率性能的影响，定义性能增益函数 $g(x)$ 为

$$g(x)=\frac{Thp(x)/Thp(1)}{SN(x)/SN(1)}$$

其中，$Thp(x)$ 为吞吐率函数，$SN(x)$ 为状态数函数，分别表示二级分割参数为 x 时的系统吞吐率和状态数。其中，$x=1$ 时，表示不进行分割，Group^2-DFA 就是 Group-DFA。由性能增益函数 $g(x)$ 的定义可知，$g(x)$ 是以 $x=1$ 时的吞吐率 $Thp(1)$ 和状态数 $SN(1)$ 为标准，将 $Thp(x)$ 和 $SN(x)$ 归一化后的比值，表示随着 x 的变化，吞吐率和状态数增长的效果。

在 snort24、bro217 和 dotstar300 3 种规则集下，分别计算 Group^2-DFA 的状态数以及吞吐率如图 6 所示。

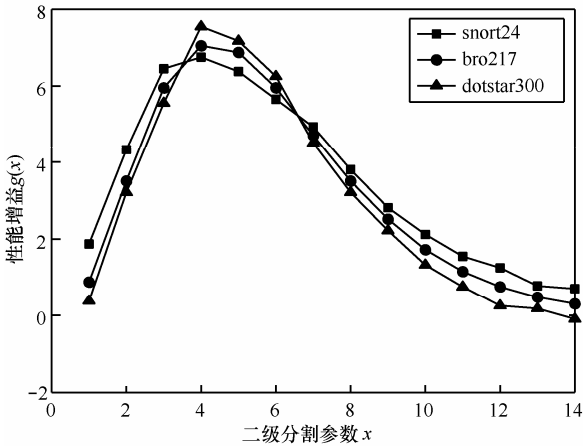

图 6　性能增益随分割参数的变化

从图 6 中可看出，对于不同的规则集，$x=4$ 时，性能增益均达到最大值，说明此时吞吐率增长较大，状态数增长相对较小，整体性能达到最佳。

面对不同的实际应用，对于空间性能要求较高时，可减小分割参数；对于吞吐率性能要求较高时，可增大分割参数，以达到合适的效果。

5.2.3　空间存储性能与系统吞吐率

空间存储占用与状态数量呈正比，因此分析算法生成的状态数可反映空间存储的性能。实验中实现了基于 SFA 算法，FEACAN 算法、CSCA 算法以及 Group^2-DFA 算法的正则表达式匹配，根据 5.2.2 节的实验结果，Group^2-DFA 算法的二级分割参数取 $x=4$。正则表达式规则选用 snort24、bro217 和 dotstar300 的混合集合，规则数量从 24 开始逐渐增加，最多选取 300 条正则表达式。

4 种算法的状态数对比情况如图 7 所示。正则表达式规模较小时，4 种算法得到的状态数差别较小；随着正则表达式规模的增长，Group^2-DFA 算法

的状态数增长最慢，近似呈线性增长，而 SFA 算法、FEACAN 算法以及 CSCA 算法的状态数增长较快，可以看出，Group^2-DFA 算法在减少状态数方面的优势较为明显。

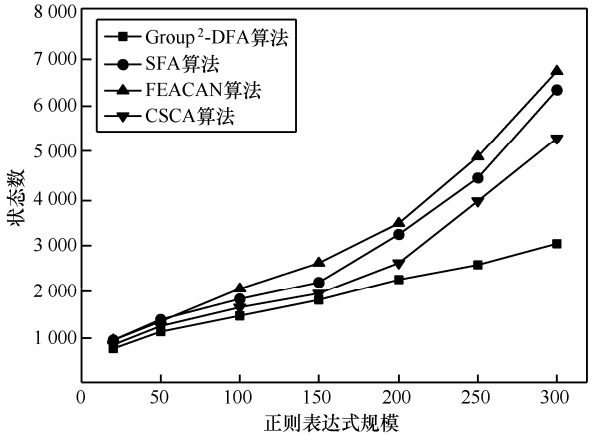

图 7　4 种算法状态数对比

表 2 给出了 4 种规则集合下，Group^2-DFA 相对于 DFA 的状态减少率。

表 2　正则表达式集合下 Group^2-DFA 的状态减少率

算法	snort24	snort34	bro217	dotstar300
NFA	571	882	2 130	11 145
DFA	8 334	9 753	6 532	>100 000
Group^2-DFA	1 743	2 356	2 974	3 341

根据表 2 计算可得，对于 4 个不同的规则集合，Group^2-DFA 的状态减少率分别为：79.1%、75.9%、54.4%以及大于 96.6%。

正则表达式集合 bro217 中，处于相交关系的状态较少，状态爆炸不明显，Group^2-DFA 算法对于状态数的减少百分比较小；测试中，Group^2-DFA 算法对于 snort 集合、dotstar_300 集合的性能较好，能达到 75%以上。另外，由于 dotstar_300 生成的 DFA 数目大于 1×10^5 个，超出预设的内存占用，没有得到全部的 DFA 状态数。

图 8 给出了 4 种算法的吞吐率（Gbit/s）对比情况。从图 8 中可以看出，随着正则表达式规模的增加，Group^2-DFA 算法的吞吐率较为稳定，这是由于 Group^2-DFA 算法的吞吐率主要受到并行等价 NFA 数量的影响，与参数 x 的选取有关，与正则表达式规模无关。Group^2-DFA 算法的吞吐率与 SFA 算法较为接近，相差较小，但 Group^2-DFA 算法的浮动较小，比 SFA 算法稳定。而 FEACAN 和 CSCA 的吞吐率受正则表达式规模的影响较大，虽然在正则表达式规模较小时，两者的吞吐率高于 Group^2- DFA 算法，但是随着正则表达式规模的增加，吞吐率呈下降趋势，当正则表达式大于 250 条时，其吞吐率小于 Group^2-DFA 算法。

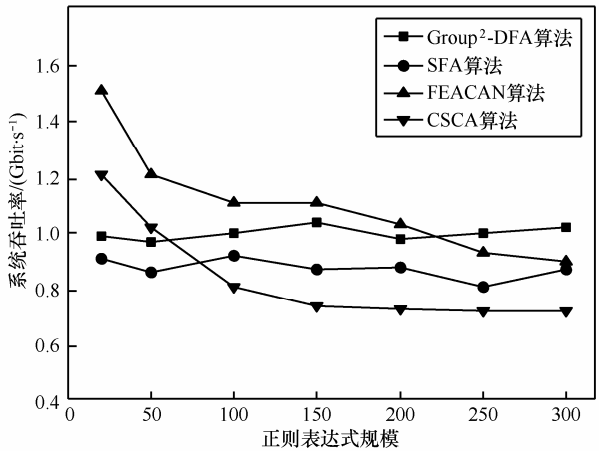

图 8　4 种算法的吞吐率对比

图 9 给出了 4 种算法处理一个字符时的平均内存访问次数。可以看出，在处理一个字符时，Group^2-DFA 算法需要访问多次内存，时间复杂度有所增长，高于其他 3 种算法。这是由于 Group^2-DFA 算法中包括两级分组结构，每一级中都包括 NFA 和 DFA 2 种形态，而 NFA 和 DFA 的状态转移表需要单独存储，导致处理字符时，可能需要读取多次内存。虽然 Group^2-DFA 算法的时间复杂度有所增长，但由于采用二级分组结构，充分利用了 DFA 的快速处理特性，所以 Group^2-DFA 算法仍然可以达到较高的吞吐率。

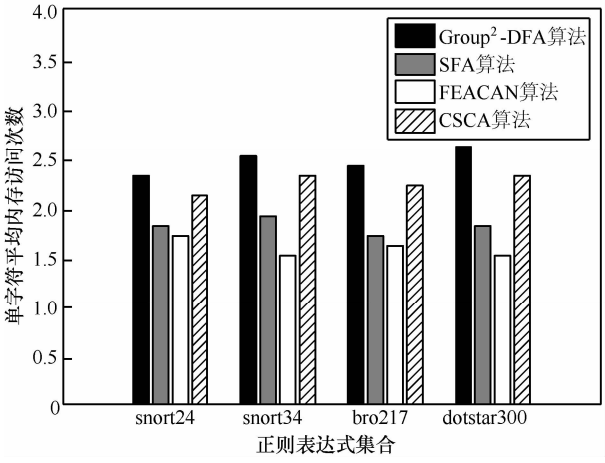

图 9　单字符平均内存访问次数

实验结果表明，Group^2-DFA 算法的状态数小于 SFA、FEACAN、CSCA 算法；当正则表达式规模增加时，Group^2-DFA 算法的吞吐率稳定在较高水平；对于不同的规则集合，Group^2-DFA 算法的单字符平均内存访问次数高于其他 3 种算法。综上所述，根据性能增益合理选取分割参数后，Group^2-DFA 算法能够达到较好的状态减少率，并且保持较高的系统吞吐率，付出的代价是单字符平均内存访问次数有一定的增加。

6 结束语

本文提出的 Group^2-DFA 算法结合 NFA 的空间和 DFA 的时间特性，以一定的时间复杂度为代价，减小了 DFA 的空间复杂度。算法通过分析 NFA 转化为 DFA 过程中产生状态爆炸的原因，引入了一种状态分类方法，构建二级分组模型，在保证系统吞吐率的前提下，有效地减轻了状态爆炸的影响。在系统结构上，Group^2-DFA 算法呈现 NFA 的并行处理特性，在内部实现中，采用单独的 DFA 处理；这种混合结构使得 Group^2-DFA 算法能够通过多核技术实现并行加速，有效地提升了系统的吞吐率。

对于大规模的正则表达式集合，分组得到的 single-DFA 数量较多，会降低系统处理的性能，进一步的研究可考虑对分组的方法进行改进，以提高处理速率。另外，由于采用单字符输入的方法，处理速率受到一定的限制，为了达到更高的系统吞吐率，可引入多字符处理机制来满足实际需求。

参考文献：

[1] JIANG L, TAN J, LIU Y. ClusterFA: a memory-efficient DFA structure for network intrusion detection[A]. Proceedings of the 7th ACM Symposium on Computer and Communications Security Information[C]. New York,USA, 2012. 65-66.

[2] BECCHI M, CROWLEY P. Efficient regular expression evaluation: theory to practice[A]. Proceedings of the 4th ACM/IEEE Symposium on Architectures for Networking and Communications Systems[C]. Colorado: ACM, 2008. 50-59.

[3] YANG Y H E, JIANG W, PRASANNA V K. Compact architecture for high-throughput regular expression matching on FPGA[A]. Proceedings of the 4th ACM/IEEE Symposium on Architectures for Networking and Communications Systems[C]. San Jose, California,USA, 2008.30-39.

[4] ZHENG K, ZHANG X, CAI Z, *et al.* Scalable NIDS via negative pattern matching and exclusive pattern matching[A]. Proceedings IEEE International Conference on Computer Communications, Joint Conference of the IEEE Computer and Communications Societies[C]. San Dieg, 2010. 1-9.

[5] 李奇越. 网络内容分析中基于硬件的字符串匹配算法的研究[D]. 合肥: 中国科技大学, 2008.
LI Q Y. String Matching Algorithm Research based on Hardware in Network, Content Analysis[D]. Hefei: University of Science and Technology of China, 2008.

[6] LIN C H, HUANG C T, JIANG C P, *et al*. Optimization of regular expression pattern matching circuits on FPGA[A]. Proceedings of Design, Automation and Test in Europe[C]. Germany, 2006. 1-6.

[7] LE H, PRASANNA V. A memory-efficient and modular approach for large-scale string pattern matching[J]. IEEE Transactions on Computers, 2013,62(5):844-857.

[8] BECCHI M, CROWLEY P. A hybrid finite automaton for practical deep packet inspection[A]. Proceedings of ACM CoNEXT Conference[C]. New York,USA, 2007.1-12.

[9] YU F, CHEN Z, DIAO Y, *et al*. Fast and memory-efficient regular expression matching for deep packet inspection[A]. ACM/IEEE Symposium on Architecture for Networking and Communications System[C]. San Jose, California,USA, 2006. 93-102.

[10] PASETTO D, PETRINI F, AGARWAL V. Tools for very fast regular expression matching[J]. Computer, 2010, 43(3):50-58.

[11] QI Y, WANG K, FONG J, *et al*. FEACAN: front-end acceleration for content-aware network processing[A]. Proceedings of 30th IEEE International Conference on Computer Communications, Joint Conference of the IEEE Computer and Communications Societies[C]. Shanghai, China, 2011. 2114-2122.

[12] LIU T, YANG Y, LIU Y, *et al*. An efficient regular expressions compression algorithm from a new perspective[A]. Proceedings of 30th IEEE International Conference on Computer Communications, Joint Conference of the IEEE Computer and Communications Societies[C]. Shanghai, China, 2011. 2129-2137.

[13] ANTONELLO R, FERNANDES S, SADOK D, *et al*. Deterministic finite automaton for scalable traffic identification: the power of compressing by range[A]. Network Operations and Management Symposium (NOMS)[C]. Piscataway:IEEE, 2012. 155-162.

[14] WOODS L, TEUBNER J, ALONSO G. Complex event detection at wire speed with FPGAs[J]. The VLDB Endowment, 2010, 3(1-2):660-669.

[15] YANG Y H E, PRASANNA V K. Space-time tradeoff in regular expression matching with semi-deterministic finite automata[A]. Proceedings of 30th IEEE International Conference on Computer Communications, Joint Conference of the IEEE Computer and Communications Societies[C]. Shanghai, China, 2011. 1853-1861.

[16] Sourcefire, SNORT[EB/OL].http://www.snort.org/snort-downloads, 2012.

[17] International computer science institute, bro intrusion detection system [EB/OL]. http://bro-ids.org/download/index.html, 2012.

作者简介：

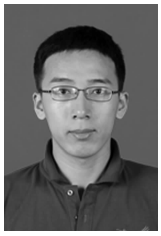

贺炜（1988-），男，山西吕梁人，国家数字交换系统工程技术研究中心硕士生，主要研究方向为高速模式匹配技术、网络特征检测技术。

郭云飞（1963-），男，河南郑州人，国家数字交换系统工程技术研究中心教授、博士生导师，主要研究方向为网络安全、宽带信息网络和高速路由器关键技术。

扈红超（1982-），男，河南商丘人，博士，国家数字交换系统工程技术研究中心讲师，主要研究方向为高速路由器关键技术、网络流量均衡技术和业务管控技术等。