ТЕОРИЯ И ПРАКТИКА МНОГОПОТОЧНОГО ПРОГРАММИРОВАНИЯ

Тема 13

Неблокирующие алгоритмы и их проблемы.

Д.ф.-м.н., профессор А.Г. Тормасов
Базовая кафедра «Теоретическая и Прикладная Информатика», МФТИ

Тема

- Краткий обзор некоторых неблокирующих алгоритмов, применяемых на практике
- Некоторые алгоритмы и подходы, созданные в последнее время, но не получившие пока распространения

Lockless структуры

- Их создание трудно
- Сложно верифицировать полученный код
- Иногда их использование невозможно
  - Вообще невозможно математически
  - Возможно, но полученное решение содержит слишком много памяти и/или команд, блокирующих шину памяти
- Почти всегда используются компромиссы

Некоторые идеи

- Неблокирующие алгоритмы – слабый вариант свободы от ожидания
- Оптимистически считают, что конфликты редки и их надо считать скорее исключением, чем правилом
- Но мы должны уверенно детектировать наличие конфликта, и обычно просто рестартовать операцию

Некоторые идеи

- Для обновления разделяемых данных неблокирующие алгоритмы используют чаще всего следующий алгоритм:
  - Подготовить копию (возможно частичную) объекта, который вы хотите обновить
  - Обновить копию
  - Заменить основные данные на сделанную копию атомарным образом, например, заменив указатель на нее через CAS операцию
  - Если вдруг произошел конфликт, то повторить с начала, удалив текущую копию
- Подразумеваем, что объект сконструирован как динамический набор узлов, соединённых указателями (есть указатель для каждого объекта, через который осуществляется исключительный доступ).

Некоторые идеи

- Еще одна идея реализации – не требовать указателей и их атомарной замены, а использовать порядок чтения-записи

- Пример – разделяемые буферы, алгоритм Лампорта

  L. Lamport, “Concurrent reading and writing” Communications of the ACM, vol. 20, no. 11, pp. 806–811, Nov. 1977

Некоторые идеи

- Для свободной от ожидания реализации часто используются сложные алгоритмы
- Одна из идей – копирование объекта в разные буферы, и перенаправление соисполняемых операций в разные буферы для избежания конфликтов.
  - Буфер с наиболее последним значением обычно считается актуальным и активируется через сменный указатель (так как уже было описано)

Некоторые идеи

- Еще одна идея – помощь в работе другим методам
  1. Каждая операция, назовем ее операция$_i$, сначала анонсирует некоторую информацию о том, что она собирается делать с разделяемым объектом в некой глобальной структуре.
  2. Затем, эта глобальная структура на другие операции, которые анонсированы и не завершены, например, из за прерывания. Анонсированные операции затем выполняются операцией$_i$, обычно в несколько шагов, которые каким то образом используют атомарные примитивы для гарантий.
  3. Когда все анонсированные операции получили помощь, то сама уже операция$_i$ выполняется примерно так же, как когда она помогала другим операциям. Так как все остальные соисполняющиеся операции так же следуют общей схеме помощи, то может оказаться что и операцияi помогает сама себе, то есть процедура помощи фактически работает рекурсивно.
- Этот метод требует, чтобы операция была разбита на несколько шагов, удовлетворяющих определенным требованиям, нужным для гарантии непротиворечивости между соисполняемыми операциями, которые пытаются помочь в выполнении операции.

Ядро Linux

- Структуры, используемые в ядре Linux (2.6)
  - krefs (lockless counters – самый типичный пример использования низкоуровненвых счетчиков)
  - seqlocks (подход, отчасти аналогичный транзакционной памяти по идеологии)
  - Ring buffer (kfifo.h)
  - RCU (radix tree в кеше страниц файловой системы)

krefs

- Самая стандартная схема использования атомарных инструкций
- Применяется для подсчета ссылок на объект
- По удалению последней ссылки объект обычно удаляется

krefs

использование

```
struct foo {…
    struct kref kref;
};
// инициализация вместе со структурой
struct foo *foo;
foo = kmalloc(sizeof(*foo),GFP_KERNEL);
kref_init(&foo->kref, foo_release);
// увеличение-уменьшение счетчика
kref_get(&foo->kref);
kref_put(&foo->kref);
// удаление
void foo_release(struct kref *kref)
{ struct foo *foo;
  foo=container_of(foo,struct foo,kref);
  kfree(foo);
}
```

реализация

```
void kref_init(struct kref *kref,
      void (*release), (struct kref *kref))
{   atomic_set(&kref->refcount,1);
    kref->release = release;
}
struct kref *kref_get(struct kref *kref) {
atomic_inc(&kref->refcount);
    return kref;
}
…
down (&disconnect_sem);
…
kref_put(&dev->kref);
up(&disconnect_sem);
```

seqlocks

- sequential lock
- Придуман для следующей схемы:
  - предохраняемый разделяемый ресурс мал и прост
    - Обычно не содержит указателей
  - часто используется на чтение
  - запись редка, но тоже должна быть быстрой
- Читатель получает полный быстрый доступ к ресурсу без ожидания
  - Плата – требует проверки условия коллизии с писателем на выходе (счетчик)
  - Повтор операции чтения, если коллизия с писателем
- Писатель должен получить исключительный доступ к данным через явную блокировку

seqlocks

```
// вариация на тему read-write lock

// использование последовательного блока
// читатель всегда перед работой получает некое
// целое значение seq

unsigned int seq;

do {

    seq = read_seqbegin(&the_lock);

    /* Do what you need to do */


// на выходе мы всегда проверяем значение seq
} while read_seqretry(&the_lock, seq);
// выходим только если оно не изменилось


// если изменилось, то писатель уже начал работу
// и надо повтороить операцию чтения
```

```
// писатель всегда использует
// традиционный блок «от себе подобных»
// никогда не ждет читателя! То есть, быстр
   void write_seqlock(seqlock_t *lock);
// Или
   void write_tryseqlock(seqlock_t *lock);
```

- Более эффективен когда много читателей и мало писателей
- Хотя может быть «активная блокировка»
- Писатель может инвалидировать значение указателя если он содержится в разделяемой области, обычно не применяется
  - рекомендуется использовать RCU
- нельзя отлаживать в дебагере, так как исполнение кода почти всегда вызовет retry !

RCU

- Оптимизировано для частого чтения и редкой записи
- Защищенный ресурс должен быть доступен только через один указатель, и все ссылки на него должны обрабатываться атомарно
- Для изменения данных писатель делает себе полную копию, меняет копию и атомарно меняет указатель на свою копию
- Данные освобождаются после удаления ссылок на них
- В невытесняющем ядре накладные расходы на чтение – 0! Даже барьер памяти не нужен

RCU

чтение

```
struct my_stuff *stuff;

// быстр и ничего не ждет
rcu_read_lock(  );
stuff =
find_the_stuff(args...);
do_something_with(stuff);
rcu_read_unlock(  );
```

запись

- Выделить память для копии
- Скопировать
- Изменить
- Заменить указатель (+барьер)
- Дождаться выполнения кода на каждом процессоре
  - Или сделать refcount
- Освободить память (оригинал)

Неблокирующий стек Treiber

добавление

```
struct Node {
    value_t data;
    Node *next;
};
Node *S;

void push(value_t v)
{
    Node *t, *x = new Node();
    x->data = v;
    do { t = S;
        x->next = t;
    } while(!CAS(&S,t,x));
}
```

удаление

```
void init()
{
    S = NULL;
}
value_t pop()
{
    Node *t, *x;
    do {
        t = S;
        if (t == NULL)
            return EMPTY;
    x = t->next;
    } while(!CAS(&S,t,x));
    return t->data;
}
```

Неблокирующий стек Treiber

- Функция init инициализирует структуры.
- Операция push:
  1. Выделяется память нового узла x;
  2. Читаем текущее значение указателя верхушки стека S;
  3. Устанавливает поле next нового узла в считанное значение S;
  4. Атомарно обновляет верхушку стека адресом нового узла x.
- Если значение указателя между 2 и 4 меняется и не установлено в его начальное значение, то операция CAS не выполняется и операция запускается повторно.
- Операция pop работает аналогично.
- Алгоритм свободен от блокировок, но не от ожидания

Неблокирующая очередь

- Предложена Михаэлем и Скоттом «по мотивам» стека Трибера, как односвязный список с указателям на Head и Tail.
- Head всегда указывает на пустой узел, Tail – на последний или следующий за последним узел
- Использует CAS и счетчик (от ABA)
- Dequeue работает так, что Tail не указывает ни на удаляемый узел, ни на его предшественника (удаленный узел можно повторно использовать)
- Для обеспечения согласованности используется последовательность операций чтения, перезачитывающих значения (убедиться, что они неизменны)
- Алгоритм линеаризуем (есть моменты изменения состояния, и состояние очереди никогда не может быть неправильно прочитано, нет «переходных процессов»)

Неблокирующая очередь

структуры

```
struct Pointer {
    Node *ptr;
    unsigned int counter;
};

struct Node {
    value_t value;
    Pointer next;
};

struct Queue {
    Pointer Head;
    Pointer Tail;
};

Queue *;
```

инициализация

```
void init(Queue *q)
{
    Node *x = new Node();
    x->next.ptr = NULL;
    q->Head = <x,0>;
    q->Tail = <x,0>; // один узел
}
```

Неблокирующая очередь

добавление

```
void enqueue(Queue *q,
             value_t value)
{
  Node *x = new Node();
  x->value = value;
  x->next.ptr = NULL;
  while(1)
  {
    // читаем ptr+cnt вместе!
    Pointer t = q->Tail;
    Pointer n = t.ptr->next;
```

добавление

```
    if (t == q->Tail) // согласованы?
    {
      // t на последний узел?
      if (n.ptr == NULL)
      {
        // пытаемся вставить в конец
        if (CAS(&t.ptr->next, n,
           <x,n.count+1>))
           break; // закончили
      } else // t - не последний узел
        CAS(&q->Tail, t, // след. узел
           <n.ptr,t.count+1>);
    }
  } // добавленный узел - в Tail
  CAS(&q->Tail,t,<x,t.counter+1>);
}
```

Неблокирующая очередь

удаление

```
BOOL dequeue(Queue *q,
             value_t *pvalue)
{
  while(1) {
  // читаем значения
  Pointer t=q->Tail, h=q->Head,
          n=h->next;
  if (h == q->Head) // согласованы?
    // пусто или хвост сзади?
    if (h.ptr == t.ptr)
    {
      if (n.ptr == NULL)
        // очередь пуста
        return FALSE;
```

удаление

```
      // хвост сзади, двигаем вперед
      CAS(&q->Tail, t,
          <n.ptr,t.count+1>));
    } else // на хвост не смотрим
    { // читаем здесь, иначе другой
      // dequeue удалит следующй
узел
      *pvalue = n.ptr->value;
      if (CAS(&q->Head, h,
          <n.ptr,h.count+1>))
        break; // сл. узел для
головы
    }
  } // while
  free(h.ptr);
  return TRUE;
}
```

Без атомарных инструкций

- Кольцевой FIFO буфер с SWSR
- RCU с SWMR
  - Читатель и писатель свободны от ожидания
    - До момента рекламации памяти писателем
- Алгоритм Деккера (только для 2 потоков, свободен от блокировки и зависания, требует барьеров)
- Fastflow – базируется на SRSW очередях, реализует произвольную сеть передачи информации

Алгоритм Деккера

Поток 1

```
boolean flag[2] = {false, false};
int turn = 0; // или 1

flag[0] = true;
while (flag[1] == true) {
    if (turn != 0) {
        flag[0] = false;
        while (turn != 0)
            ;
        flag[0] = true;
    }
}
// критическая секция
...
turn = 1;
flag[0] = false;
// конец критической секции
```

Поток 2

```
flag[1] = true;
while (flag[0] == true) {
    if (turn != 1) {
        flag[1] = false;
        while (turn != 1)
            ;
        flag[1] = true;
    }
}
// критическая секция
...
turn = 0;
flag[0] = false;
// конец критической секции
```

список с пропусками skip list

- Типовые поисковые структуры с нагрузкой типа
  90% - lookup, 9% - add, 1% - del
- Аналог – балансированные деревья (AVL, красно-черные и др)
  - Общая проблема ребалансировки после add/del – это глобальная плохо параллелизуемая операция
- Список с пропусками, предложен в 90-х годах
  - Вероятностная структура с логарифмическим поиском
    - O(log(n)) в среднем, O(n) в худшем
  - Нет глобальной ребалансировки
- Далее рассмотрим пример из книги Херлихая и Шафита

список с пропусками skip list

- Многоуровневый дублирующий набор списков
  - Список выше уровнем есть часть низкоуровневого
  - Они все упорядочены

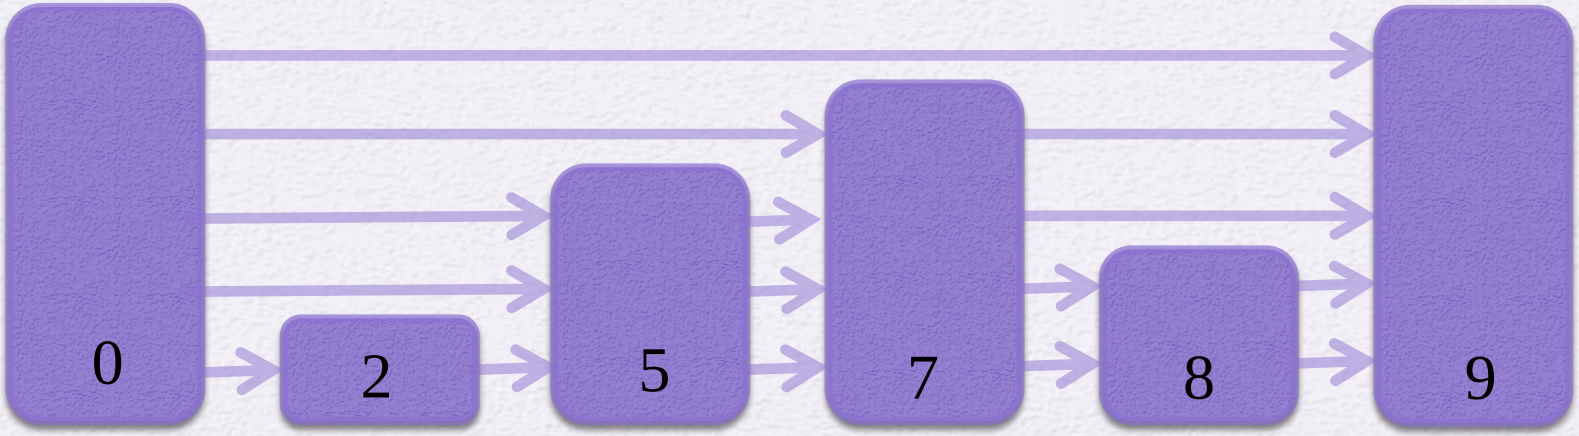

список с пропусками skip list

- При поиске мы ищем сверху вниз (пример - поиск 8)
  - Отбрасываем то, что сзади

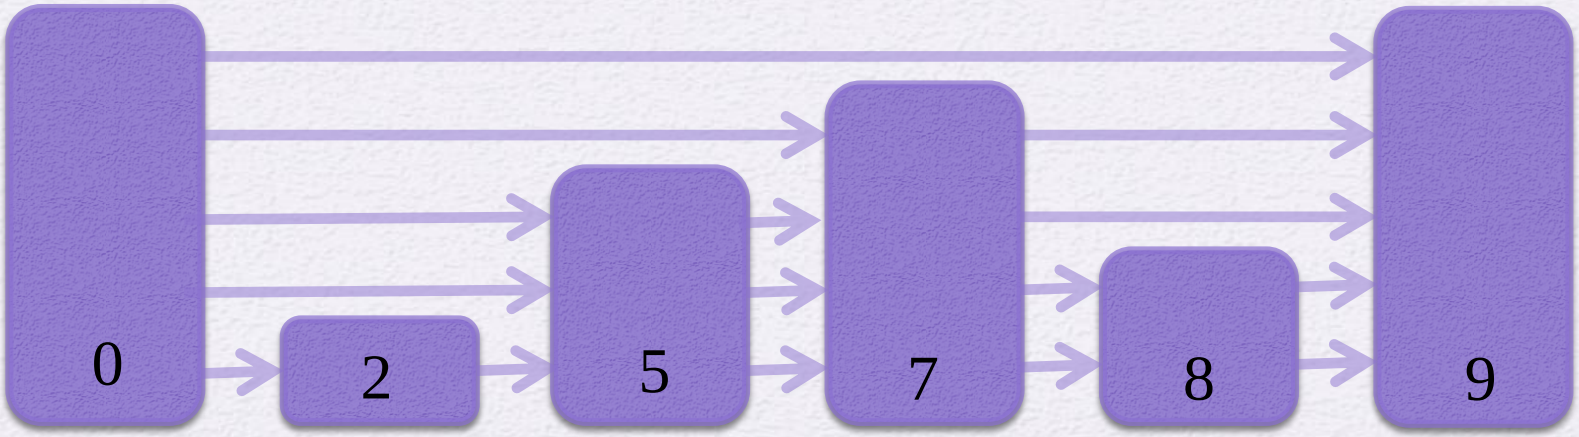

список с пропусками skip list

- Каждый уровень номер i перепрыгивает примерно 2^i узлов
  - среднее расстояние между узлами в уровне
- Высоты узлов выбираются случайно, так что гарантии только вероятностные
- Неблокирующая реализация использует неблокирующий односвязный список для каждой «башни»
- В процессе работы каждая операция «помогает» каждой
- Детали реализации можно найти в
  M. Fomitchev. Lock-free linked lists and skip lists. Master's thesis, York University, October 2003. http://www.cs.yorku.ca/~mikhail.

Хэш таблицы

- О таблице с открытой адресацией, реализующий конечный автомат, будет рассказано в следующей лекции
- Сейчас коротко рассмотрим неблокирующую таблицу

Неблокирующий хэш

- Предложено в
  H. Gao, J. F. Groote, W. H. Hesselink, "Almost Wait-Free Resizable Hashtables," ipdps, vol. 1, pp.50a, 18th International Parallel and Distributed Processing Symposium (IPDPS'04)

- 126 операторов псевдокода реализации, из них
  - 42 – insert, find, delete
  - 30 – getAccess/releaseAccess
  - 46 – new Table, refresh, migrate, moveContents
  - 6 – moveElement

- 2 человеко-года построения алгоритмов машинной верификации, более 200 инвариантов доказано, примерно дюжина ошибок обнаружена в ходе этого процесса

Неблокирующий хеш

- Основной алгоритм
  - { getAccess; (find/delete/insert)*; releaseAccess;}
  - Считает количество обратившихся процессов
  - Использует открытую адресацию
  - помечает удаленные неудаляемым символом
  - при переполнении таблицы переносит содержание в новую
- Реализация непроста, много разных состояний

Таблица с открытой адресацией

- Предложено как упрощение Gao в
  Chris Purcell and Tim Harris. Non-blocking hashtables with open addressing. Distributed Computing, pages 108–121, 2005
- Достоинства
  - Все лежит только внутри таблицы, нет указателей
  - хорошая локальность по кэш линии (при отсутствии коллизий нужна только одна линия!)
  - нет “пометок удаления” - не надо реорганизовывать
  - Поддерживается прозрачная миграция и рост таблиц
- Недостатки
  - Может хранить только ключ без значения - нельзя использовать для словарей
  - ключи нельзя модифицировать, можно только удалить

Таблица с открытой адресацией

- Соисполняемые процессы добавления и удаления непросты, так как заранее неизвестно, в какую позицию попадет ключ
  - Недостаточно просто вставить в первую попавшуюся свободную позицию, так как соисполнение процедуры удаления может изменить позицию «первого» элемента, и может появиться потенциально два одинаковых ключа!
- Каждая позиция есть пара атомарно модифицируемых значений <состояние, ключ>
  - Состояния принимают значения
    - Empty busy inserting member
  - ключ определен для последних двух значений

Таблица с открытой адресацией

- Для решения проблемы с добавкой она разбита на 3 стадии
  - Резервируется пустая позиция и этот факт анонсируется помещением туда флага inserting
  - Проверяются другие потенциальные места, где может оказаться ключ
    - при соисполнении вставки в «процессе» или
    - уже добавленный до того
  - Если нашелся другой вставленный ключ, то текущая процедура завершается неуспешно, а позиция чистится
  - Если другой процесс вставки в процессе, то он помечается как busy и блокирует другие процессы
  - В последней стадии при помощи CAS статус меняется на member
- Основная реализация является свободной от блокировок

Таблица с открытой адресацией

```
bool  CollisionInBucket(int h, int index)
{
  versionstate temp1(GetBucket(h,index)->vs);
  if (IsReadableKey((State)temp1.state))
    if (Hash(GetBucket(h,index)->key) == h )
    {
      versionstate temp2(GetBucket(h,index)->vs);
      if (IsReadableKey(temp2.state))
        if (temp1.version == temp2.version)
          return true;
    }
  return false;
}

void ConditionallyRaiseBound(int h, int index)
{
  Bounds old, nb;
  do
  { old = Bounds(bounds[h]);
    nb  = Bounds(max(old.bound,(unsigned)index),false);
  } while (!CAS32(bounds+h, old, nb));
}
```

```
void ConditionallyLowerBound(int h, int index)
{ Bounds bs(bounds[h]); // Allow maximum < index
  if (bs.scanning == true)
    CAS32(bounds+h, bs, Bounds(bs.bound, false));

  if (index > 0) // If maximum > 0, set maximum < index
    while (CAS32(bounds+h, Bounds(index,false),
                 Bounds(index,true)))
    { int i = index-1; // Scanning: scan for new max
      while ((i>0) && ! CollisionInBucket(h,i))
        i--;
      CAS32(bounds+h, Bounds(index,true),
            Bounds(i,false));
    }
}
bool Find(Key key)
{ Key h(Hash( key ));
  unsigned int maximum(GetProbeBound( h ));
  for( unsigned int i =0; i <= maximum; i++ )
  { versionstate vs(GetBucket(h, i)->vs); // atomic read
    if ((vs.state==Member) && (GetBucket(h,i)->key==key))
    if (GetBucket(h,i)->vs==versionstate(vs.version,Member))
      return true;
  }
  return false;
}
```

Таблица с открытой адресацией

```
bool NB_HashTable::Add(NB_Key key)
{ Key h(Hash( key )); unsigned int version;
retry:
  int i=-1; // Reserve a cell
  do
  { if (++i >= (signed)size)
      goto retry; // table full - can be only temporary
    versionstate vs=GetBucket(h,i)->vs; // atomic read
    version = vs.version;
  } while (!CAS32(&(GetBucket(h,i)->vs),
    versionstate(version,Empty), versionstate(version,Busy)));
  GetBucket(h,i)->key = key;
  for(;;) // Attempt to insert a unique copy of k
  { GetBucket(h,i)->vs = versionstate(version,Visible);
    ConditionallyRaiseBound(h,i);
    GetBucket(h,i)->vs=versionstate(version,Inserting);
    bool res = Help(key,h,i,version);
    if(!(GetBucket(h,i)->vs==versionstate(version,Collided)))
      return _true;
    if (!res)
    { ConditionallyLowerBound(h,i);
      GetBucket(h,i)->vs = versionstate(version+1,Empty);
      return _false;
    }
    version++;
  }
}
```

```
bool Del(Key key) // Remove k from the set if it is a member
{
  Key h(Hash( key ));
  unsigned int maximum(GetProbeBound( h ));
  for( unsigned int i =0; i <= maximum; i++ )
  {
    versionstate vs(GetBucket(h, i)->vs); // atomic read
    if ((vs.state==Member) && (GetBucket(h,i)->key==key) )
    {
      if (CAS32(&(GetBucket(h,i)->vs),
                versionstate(vs.version,Member),
                versionstate(vs.version,Busy)))
      {
        ConditionallyLowerBound(h,i);
        GetBucket(h,i)->vs = // atomic
                versionstate(vs.version+1,Empty);
        return _true;
      }
    }
  }
  return false;
}
```

Таблица с открытой адресацией

```
// Return true if no other cell seen in member state
bool  Help(Key key, int h, int i, int ver_i) // Attempt to
insert k at i
{
  int maximum(GetProbeBound( h )); // Scan through probe
sequence
  for(  int j=0; j <= maximum; j++ )
  {
    if (i != j)
    {
      versionstate vs_j(GetBucket(h,j)->vs);
      unsigned int ver_j = vs_j.version;
      if ((vs_j.state==Inserting)&&(GetBucket(h,j)->key==key))
      {
        if (j < i) // Help inserts found in the probe sequence
        {
          if (GetBucket(h,j)->vs==versionstate(ver_j,Inserting))
          {
            CAS32(&(GetBucket(h,i)->vs),
                  versionstate(ver_i,Inserting),
                  versionstate(ver_i,Collided));
            return Help(key,h,j,ver_j);
          }
        } else
        { // Fail insert found later in the probe sequence
          if (GetBucket(h,i)->vs==versionstate(ver_i,Inserting))
          {
            CAS32(&(GetBucket(h,j)->vs),
                  versionstate(ver_j,Inserting),
                  versionstate(ver_j,Collided));
          }
        }
      }
      vs_j = GetBucket(h,j)->vs; // Abort if k already a member
      ver_j = vs_j.version;
      if ( (vs_j.state == Member) && (GetBucket(h,j)->key==key) )
      {
        if (GetBucket(h,j)->vs==versionstate(ver_j,Member))
        {
          CAS32(&(GetBucket(h,i)->vs),versionstate(ver_i,Inserting),
                  versionstate(ver_i,Collided));
          return _false;
        }
      }
    }
  }
  CAS32(&(GetBucket(h,i)->vs), versionstate(ver_i,Inserting),
          versionstate(ver_i,Member));
  return _true;
}
```

Выводы

- Рассмотрены несколько практических и теоретических типовых структур данных и алгоритмов работы с ними, обладающих теми или иными свойствами свободы при параллельном исполнении
- Разные направления использования
  - Счетчики, Стеки и очереди, Операции с откатами (RCU, seqlock), Список с пропусками, Хеш таблицы
- На их примере рассмотрены некоторые подходы, используемые при создании таких структур
- Увы, пока они не часто применяются на практике, сложно доказательство безошибочности, а без него почти всегда есть ошибки
- Многие используют «расслабление» требований – «почти свободная от ожидания» означает для большинства случаев, кроме нечасто встречающихся на практике.
- Надо оценивать не только сложность, но и количество операций блокировки шины

(c) А. Тормасов, 2010-11 г.

Базовая кафедра «Теоретическая и Прикладная Информатика» ФУПМ МФТИ
tor@ crec .mipt .ru_