Диалоговый генератор CUDA-кода

Языки программирования и компиляторы ’2017
Всероссийская научная конференция памяти А.Л. Фуксмана

РЯС-2017

Аллазов А.Н. Гуда С.А. Морылев Р.И.
Институт математики, механики и компьютерных наук
Южный федеральный университет

Диалоговый высокоуровневый оптимизирующий распараллеливатель программ (ДВОР)

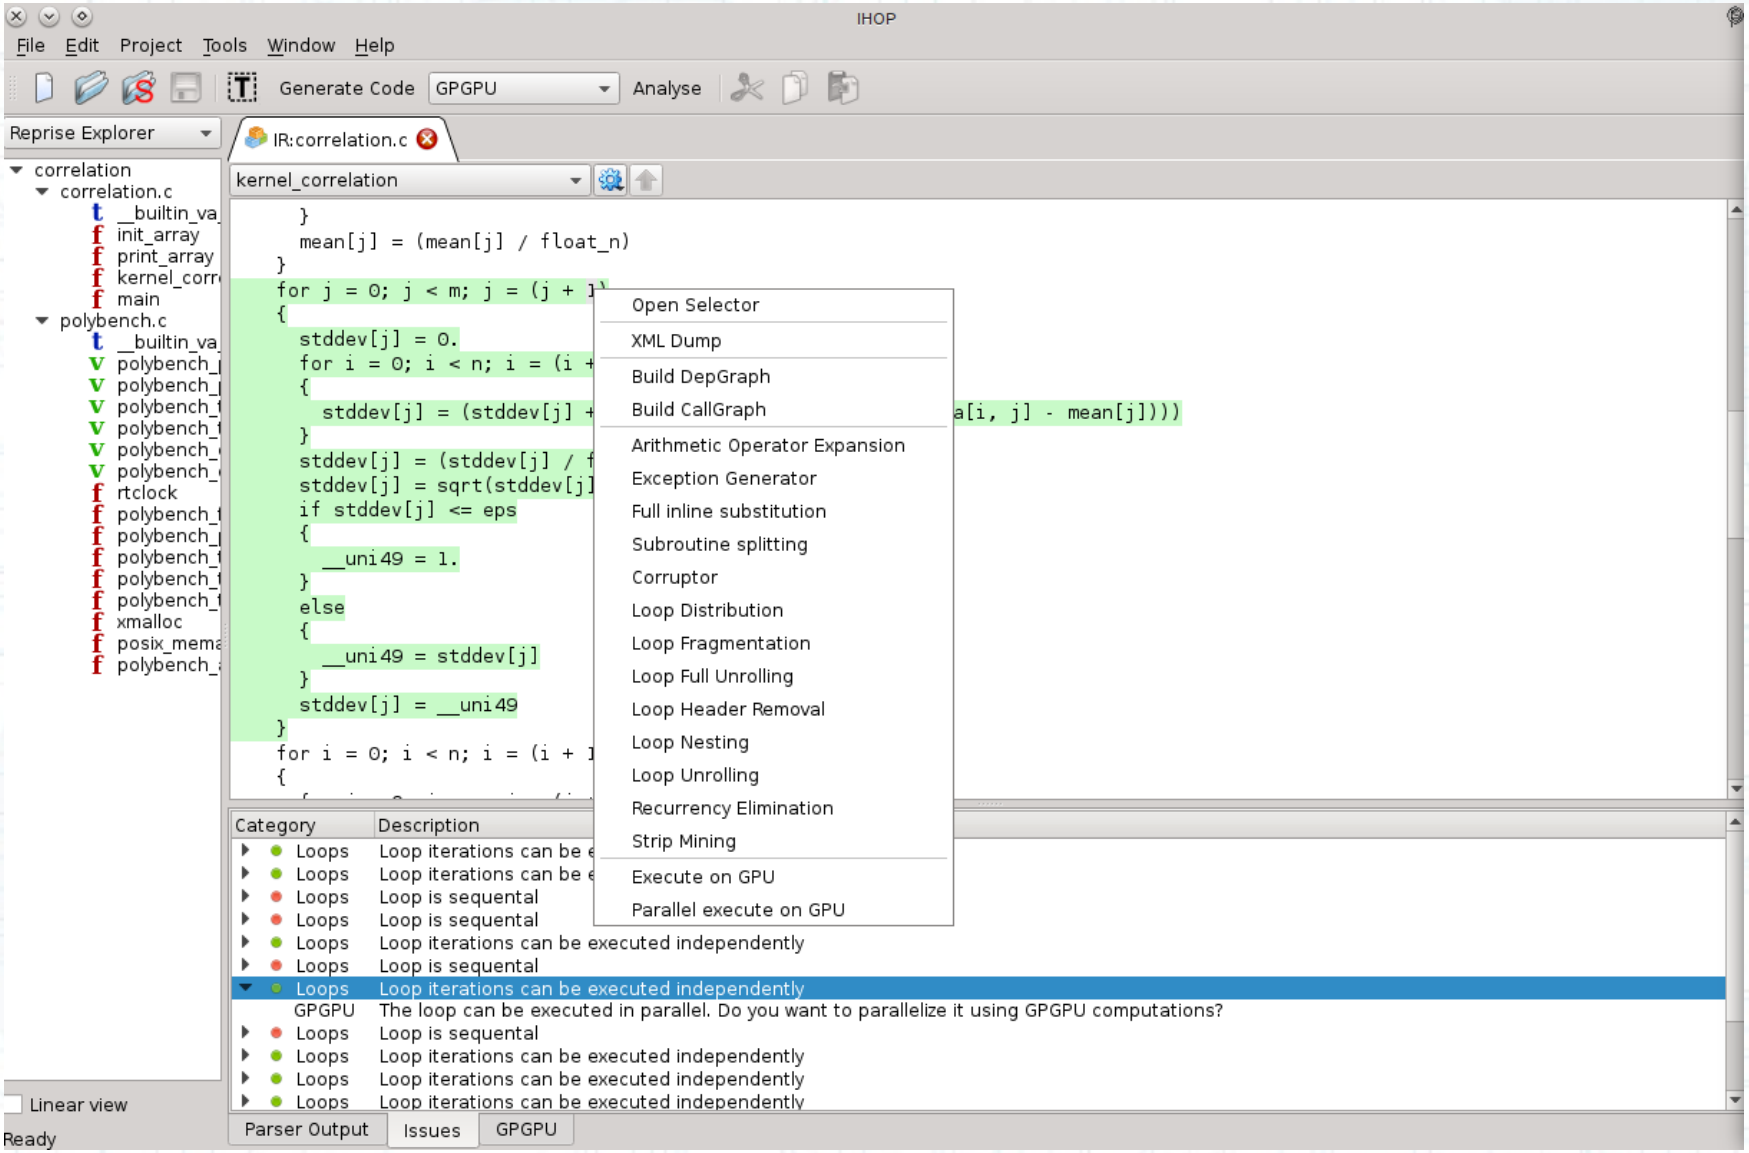

Этапы работы генератора GPU-кода

1) инициализация параметров участков кода, предварительные проверки и преобразования;
2) анализ участков кода и определение параметров отображения кода на ускоритель;
3) GPU-преобразования кода;
4) получение текстового представления кода.

Результат работы генератора

```
for (int i0 = 0; i0 < n0; i0++)
  for (int i1 = 0; i1 < n1(i0); i1++)
     for (int i2 = 0; i2 < n2(i0,i1); i1++)
        LoopBodyBlock
```

```
if (n0 > 0 && n_max1 > 0 && n_max2 > 0)
{
  dim3 blockDim = dim3(b0, b1, b2);
  dim3 gridDim = dim3(g0, g1, g2);
  kernel1<<<gridDim,blockDim>>>(...);
  gpuErrchk(cudaPeekAtLastError());
}
__global__ void kernel1(...)
{
    iψ(0) = blockIdx.x*blockDim.x+threadIdx.x
    iψ(1) = blockIdx.y*blockDim.y+threadIdx.y
    iψ(2) = blockIdx.z*blockDim.z+threadIdx.z
    if (i0<n0 && i1<n1(i0) && i2<n2(i0,i1))
       LoopBodyBlock
}
```

Анализ данных

Для каждого фрагмента кода общие для CPU И GPU ячейки памяти мы делим на три непересекающихся типа:

- внешние (для фрагмента) скалярные переменные, значения которых не меняются;
- внешние изменяемые скалярные переменные;
- массивы.

Расстановка синхронизаций общих ячеек памяти
Пример: LU-разложение матрицы

```
initMatrix(A); //initialization
for (int k = 0; k < N; k++)
{
  //fragment 1 begin
  for (int j = k + 1; j < N; j++)
    A[k*N+j] = A[k*N+j] / A[k*N+k];
  //fragment 1 end

  //fragment 2 begin
  for(int i = k + 1; i < N; i++)
    for (int j = k + 1; j < N; j++)
      A[i*N+j] = A[i*N+j] - A[i*N+k] * A[k*N+j];
  //fragment 2 end
}
```

Расстановка синхронизаций общих ячеек памяти

- Начальное расположение cudaMemcpy: после CPU и GPU-фрагментов для измененных в этом фрагменте ячеек
- Алгоритм оптимизации синхронизаций данных сдвигает cudaMemcpy вниз по графу потока управления, выносит их из циклов и удаляет дублирующиеся
- Как не допустить ошибок?

Расстановка синхронизаций общих ячеек памяти

Нужно соблюсти правило:
Рассмотрим путь на графе потока управления, соединяющий оператор на dev1, изменяющий некоторую общую для dev1 и dev2 переменную x, и оператор на dev2 с вхождением той же ячейки памяти.

На каждом таком пути должна располагаться хотя бы одна операция копирования переменной x в направлении dev1→dev2, срабатывающая раньше любой операции копирования в противоположном dev2→dev1 направлении, если последняя присутствует на данном пути.

Пример: LU-разложение матрицы

```
gpuErrchk(cudaMalloc(&A_gpu, N*N*8));
gpuErrchk(cudaMemcpy(A_gpu, A, N*N*8, cudaMemcpyHostToDevice));
for (int k = 0; k < N; k = k + 1)
{
  if (N - (k + 1) > 0)
  {
    int blockDim = 256;
    int gridDim = (N-k-1+blockDim-1)/blockDim;
    kernel0<<<gridDim,blockDim>>>(k,A_gpu,n);
    gpuErrchk(cudaPeekAtLastError());
  }
  if (N - (k + 1) > 0 && N - (k + 1) > 0)
  {
    dim3 blockDim = dim3(64,4,1);
    dim3 gridDim = dim3(
           (N-k-1+blockDim.x-1)/blockDim.x,
           (N-k-1+blockDim.y-1)/blockDim.y, 1);
    kernel1<<<gridDim,blockDim>>>(k, A_gpu, N);
    gpuErrchk(cudaPeekAtLastError());
  }
}
gpuErrchk(cudaMemcpy(A, A_gpu, N*N*8, cudaMemcpyDeviceToHost));
```

Отображение циклов на измерения пространства потоков

```
for (int i0 = 0; i0 < n0; i0++)
  for (int i1 = 0; i1 < n1(i0); i1++)
    for (int i2 = 0; i2 < n2(i0,i1); i2++)
      LoopBodyBlock
```

```
i0 = blockIdx.x*blockDim.x+threadIdx.x
i1 = blockIdx.y*blockDim.y+threadIdx.y
i2 = blockIdx.z*blockDim.z+threadIdx.z
```

Плюс еще 5 способов. Какой выбрать?

Статическая профилировка

- Определим коэффициенты при счетчиках циклов в каждом обращении к массиву

  X[a0*i0 + a1*i1 + a2*i2 + p]

- Будем различать 3 типа коэффициентов:
  - a=0
  - a=const < Cache size
  - a – unknown или >=Cache size
- Оценим время доступа к памяти для всех комбинаций типов коэффициентов

Статическая профилировка

$$t_{11} = 0, \quad t_{12} = \min\left((CS/a_1)b_0,\, BV\right)^{-1}, \quad t_{13} = b_0^{-1},$$
$$t_{21} = \min\left((CS/a_0)b_1,\, BV\right)^{-1},$$
$$t_{22} = \min\left(CS/(a_0b_0a_1)b_0 + CS\%(a_0b_0a_1)/a_0,\, BV\right)^{-1},$$
$$t_{23} = \min(CS/a_0, b_0)^{-1}, \quad t_{31} = b_1^{-1}, \quad t_{32} = 1, \quad t_{33} = 1.$$

Время – в расчете на 1 поток

За единицу времени принято время чтения одной кеш-линейки.

Отображение циклов на измерения пространства потоков - естественное

Статическая профилировка

Для 3х-мерного гнезда:

$$
\begin{aligned}
&t_{111} = 0, \quad t_{121} = \min\left((CS/a_1)b_0b_2,\, BV\right)^{-1},\\
&t_{131} = (b_0b_2)^{-1}, \quad t_{211} = \min\left((CS/a_0)b_1b_2,\, BV\right)^{-1},\\
&t_{221} = \min\left((CS/(a_0b_0a_1)b_0 + CS\%(a_0b_0a_1)/a_0)\,b_2,\, b_0b_1\right)^{-1},\\
&t_{231} = \min((CS/a_0)b_2, b_0b_2)^{-1}, \quad t_{311} = (b_1b_2)^{-1},\\
&t_{321} = b_2^{-1}, \quad t_{331} = b_2^{-1}, \quad t_{112} = \min\left((CS/a_2)b_0b_1,\, BV\right)^{-1},\\
&t_{122} = \min\left((CS/(a_1b_1a_2)b_1 + CS\%(a_1b_1a_2)/a_1)b_0, BV\right)^{-1},\\
&t_{132} = b_0^{-1},\\
&t_{212} = \min\left((CS/(a_0b_0a_2)b_0 + CS\%(a_0b_0a_2)/a_0)b_1, BV\right)^{-1},\\
&t_{222} = \min\left(CS/(a_0b_0a_1b_1a_2)b_0b_1 + \right.\\
&\qquad +CS\%(a_0b_0a_1b_1a_2)/(a_0b_0a_1)b_0 +\\
&\qquad \left. +CS\%(a_0a_1b_0b_1a_2)\%(a_0b_0a_1)/a_0), BV\right)^{-1},\\
&t_{232} = \min(CS/a_0, b_0)^{-1}, \quad t_{312} = b_1^{-1}, \quad t_{322} = 1, \quad t_{332} = 1,\\
&t_{113} = (b_0b_1)^{-1}, \quad t_{123} = \min\left((CS/a_1)b_0,\, b_0b_1\right)^{-1},\\
&t_{133} = b_0^{-1}, \quad t_{213} = \min\left((CS/a_0)b_1,\, b_0b_1\right)^{-1},\\
&t_{223} = \min\left(CS/(a_0b_0a_1)b_0 + CS\%(a_0b_0a_1)/a_0,\, b_0b_1\right)^{-1},\\
&t_{233} = \min(CS/a_0, b_0)^{-1}, \quad t_{313} = b_1^{-1}, \quad t_{323} = 1, \quad t_{333} = 1.
\end{aligned}
$$

Сравнение с PPCG на Polybench

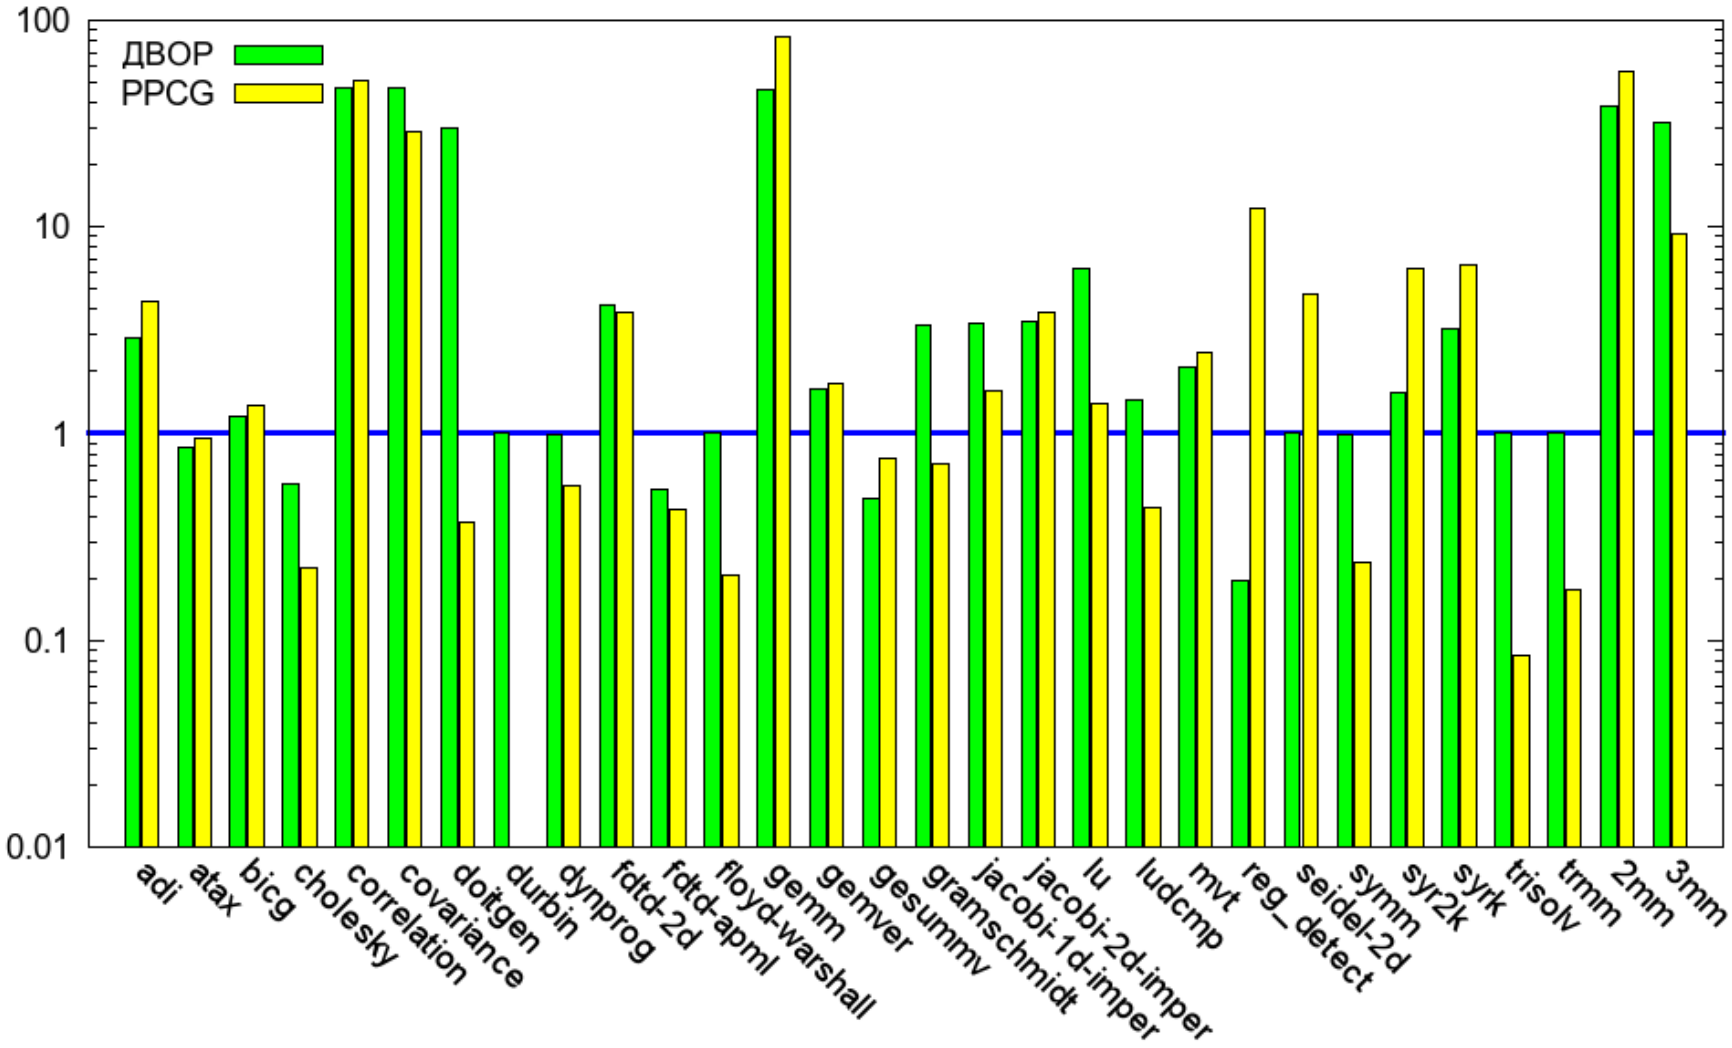

Ускорение сгенерированного кода для GPU Tesla C2075 по сравнению с CPU Intel Core i7-3820 3.60GHz (компилятор GCC с флагом -O2)

http://ops.opsgroup.ru/

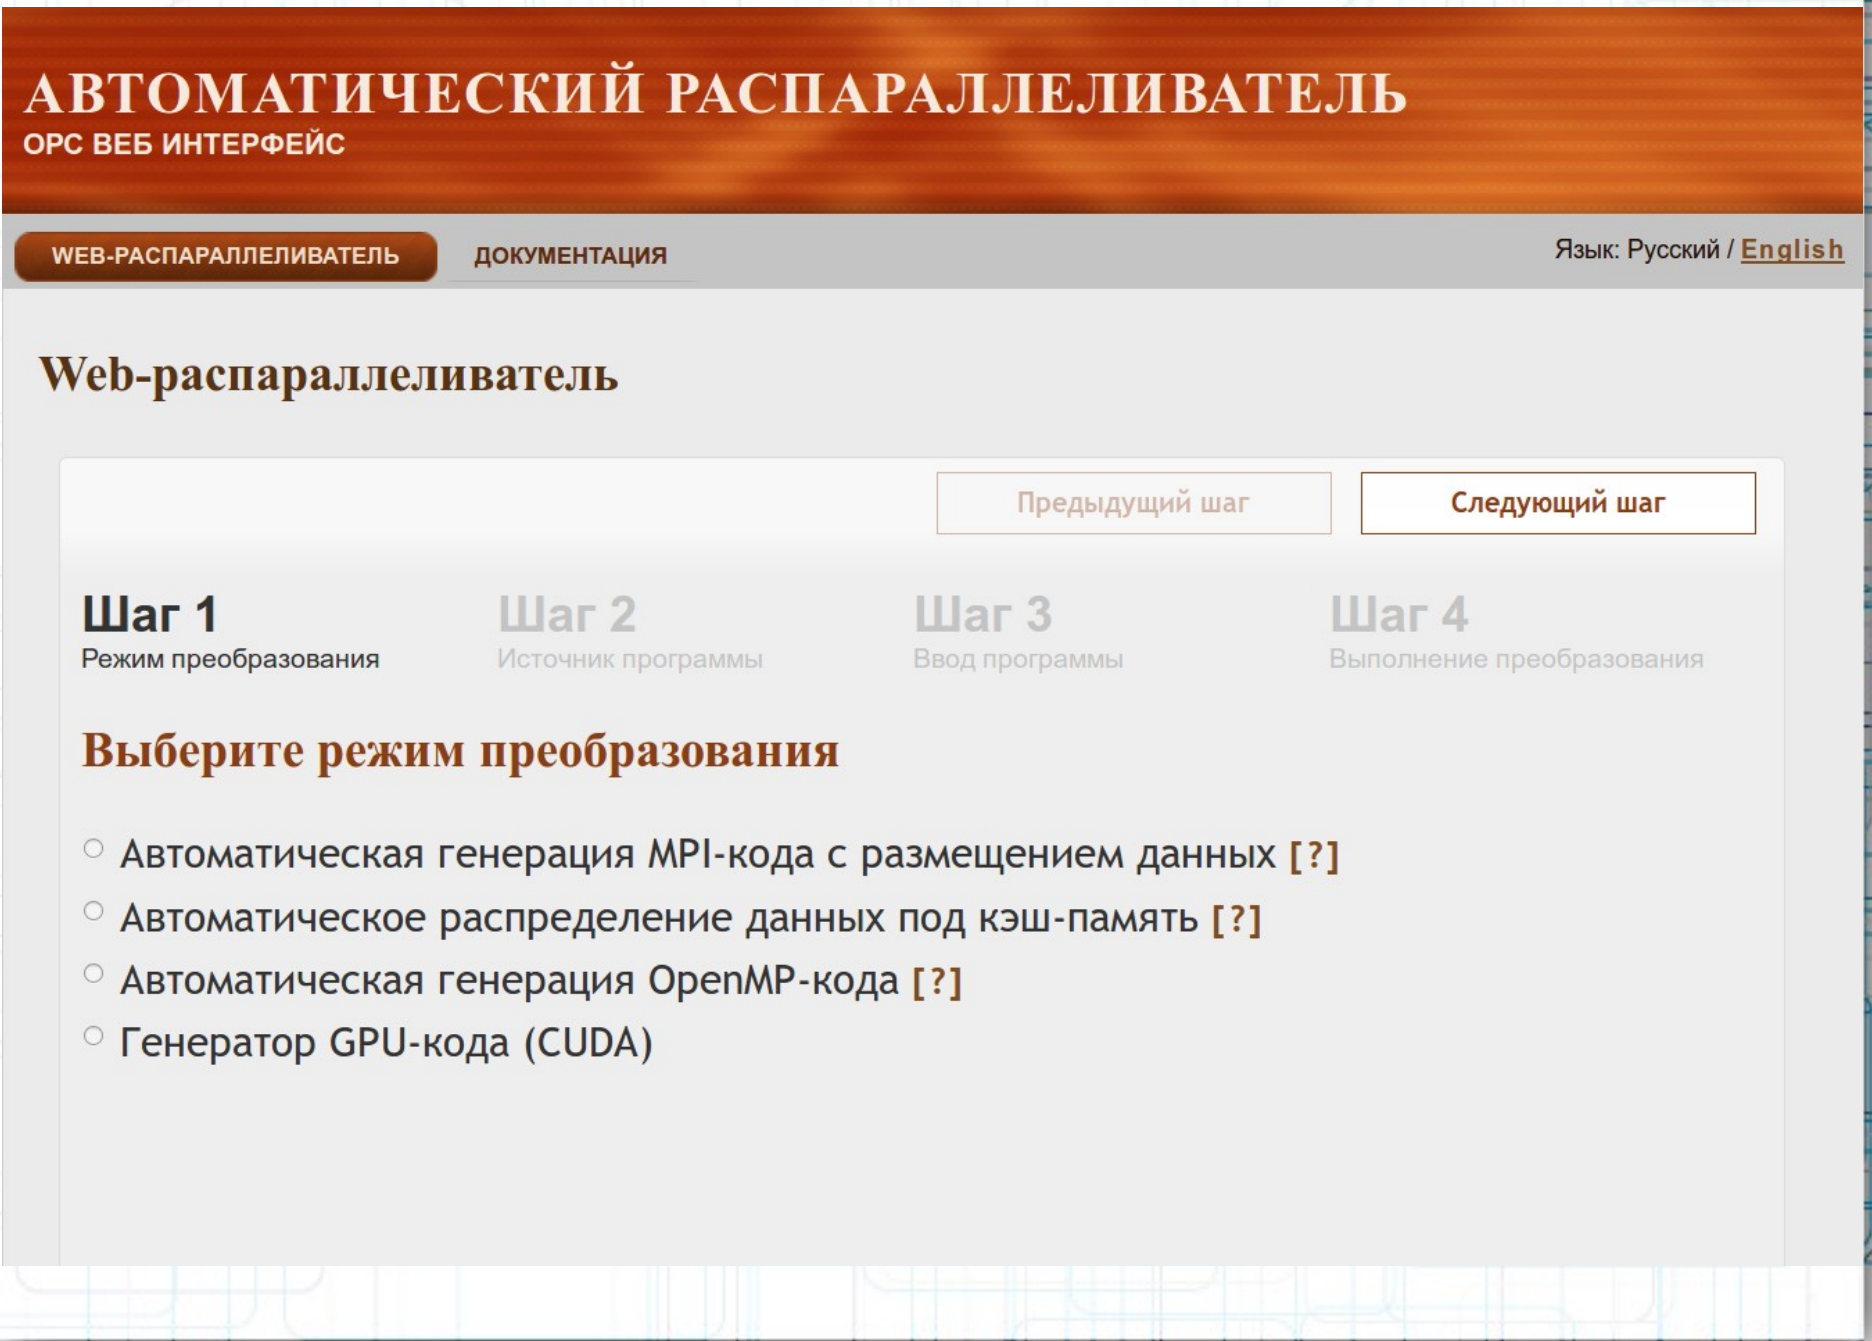

Директива #pragma ops target

```
/* E := A*B */
#pragma ops target collapse(2)
for (i = 0; i < _PB_NI; i++)
  for (j = 0; j < _PB_NJ; j++)
    {
      E[i][j] = 0;
      for (k = 0; k < _PB_NK; ++k)
        E[i][j] += A[i][k] * B[k][j];
    }
/* F := C*D */
#pragma ops target collapse(2)
for (i = 0; i < _PB_NJ; i++)
  for (j = 0; j < _PB_NL; j++)
    {
      F[i][j] = 0;
      for (k = 0; k < _PB_NM; ++k)
        F[i][j] += C[i][k] * D[k][j];
    }
/* G := E*F */
#pragma ops target collapse(2)
for (i = 0; i < _PB_NI; i++)
  for (j = 0; j < _PB_NL; j++)
    {
      G[i][j] = 0;
      for (k = 0; k < _PB_NJ; ++k)
        G[i][j] += E[i][k] * F[k][j];
    }
```