

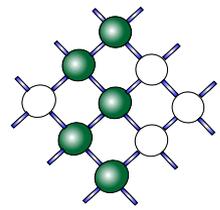
*Федеральное государственное бюджетное учреждение науки  
Институт физики полупроводников им. А.В. Ржанова СО РАН  
Лаборатория вычислительных систем  
пр. Ак.Лаврентьева, 13 , 630090, Новосибирск, Россия  
т. +7 (383) 333-21-71*

# Анализ и организация функционирования распределенных вычислительных систем, разработка параллельных алгоритмов и программ

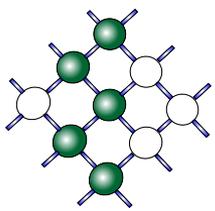
ПАВСКИЙ КИРИЛЛ ВАЛЕРЬЕВИЧ  
заведующий Лабораторией ВС ИФП СО РАН  
доктор технических наук, доцент

Новосибирск, 2024 г.

# Темы работ



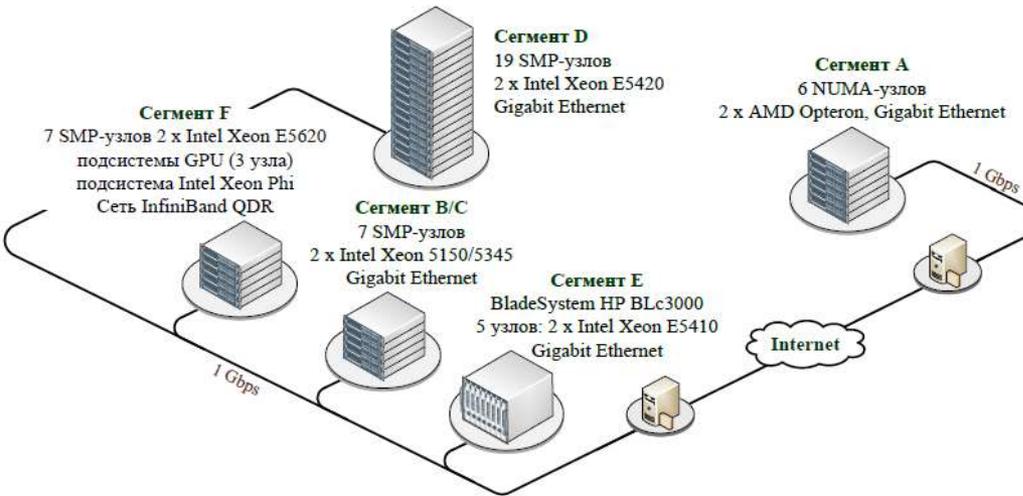
1. Исследование и разработка средств анализа функционирования масштабируемых вычислительных систем и расчет показателей надежности.
2. Разработка отказоустойчивых параллельных алгоритмов и программ для моделирования физических процессов при гетероэпитаксии германия на структурированных подложках кремния.
3. Разработка алгоритмических и программных средств исследования отказов и сбоев в высокопроизводительных вычислительных системах.
4. Разработка алгоритмов и программ моделирования объектов, построение проекций при томографии.
5. Разработка алгоритмов и программ обработки изображений для реконструкции объектов исследования методом птихографии.



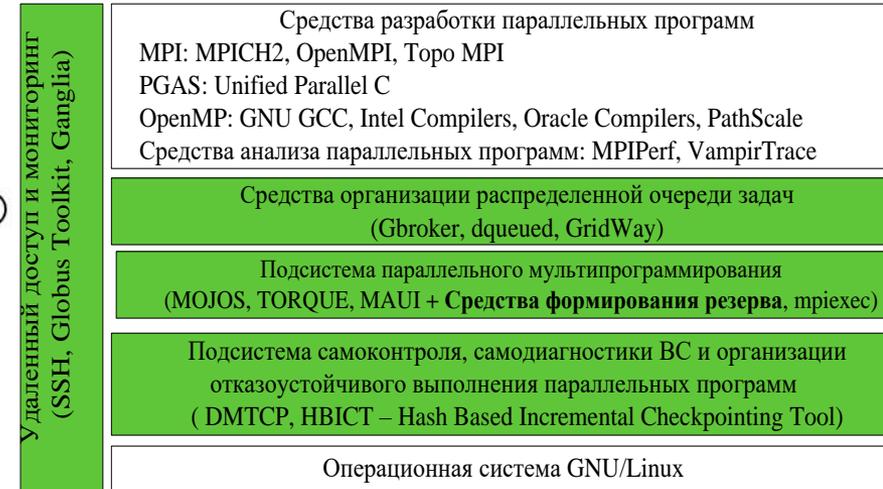
Федеральное государственное бюджетное учреждение науки Институт физики  
полупроводников им. А.В. Ржанова СО РАН  
Лаборатория вычислительных систем  
пр. Ак.Лаврентьева, 13, 630090, Новосибирск, Россия  
т. +7 (383) 333-21-71, 330-56-26

## В Лаборатории вычислительных систем ИФП СО РАН ведутся научные исследования по следующим направлениям:

- Методы, алгоритмы и системное программное обеспечение организации функционирования распределенных вычислительных систем (ВС);
- Моделирование и анализ функционирования распределенных вычислительных систем;
- Разработка параллельных алгоритмов и программ.



### Структура программного обеспечения мультикластерной вычислительной системы

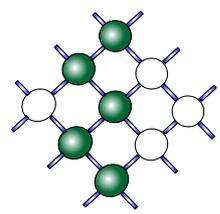


Подсистема параллельного мультипрограммирования

**Мультикластерная ВС создана ЦПВТ СибГУТИ совместно с Лабораторией ВС ИФП СО РАН.**

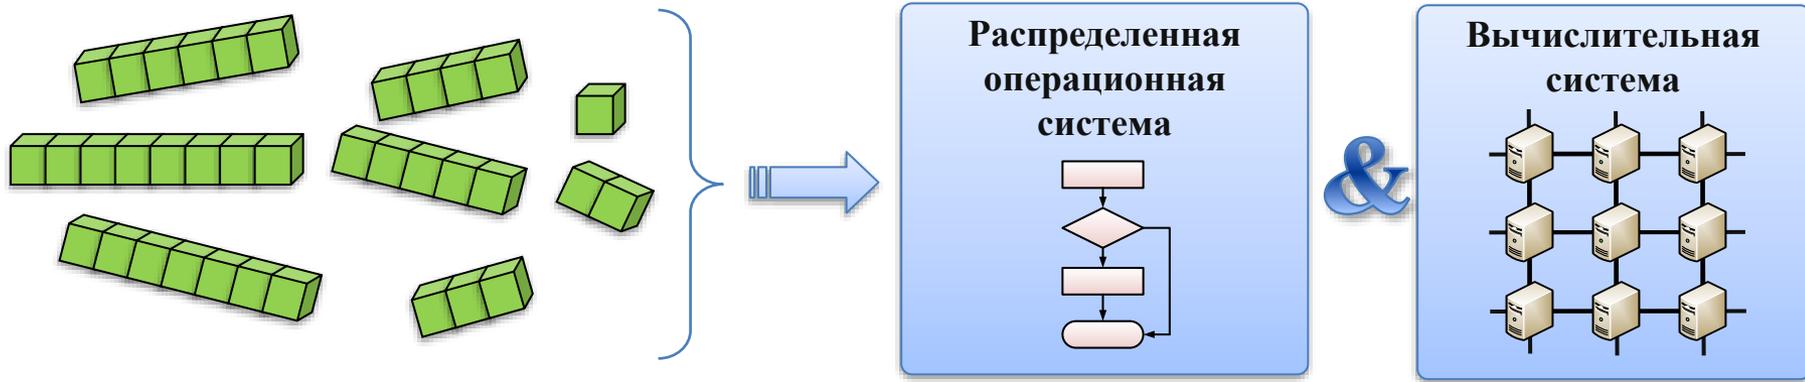
Мультипрограммные режимы функционирования организуются средствами, разработанными членами ведущей научной школы РФ (НШ-9505.2006.9, НШ-2121.2008.9, НШ-5176.2010.9, НШ-2175.2012.9, руководитель – чл.корр. РАН В.Г. Хорошевский).

Основное назначение ВС – исследование архитектуры и отработка инструментария параллельного мультипрограммирования, моделирование распределенных вычислительных технологий и подготовка научно-педагогических кадров.



# Инструментарий параллельного мультипрограммирования

*Модели, методы и программное обеспечение, предназначенное для оптимизации использования ресурсов распределенных ВС при решении множества задач, представленных параллельными программами*



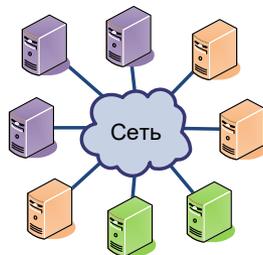
**Поток параллельных задач**

– единичный ранг

**Мультизадачные режимы**

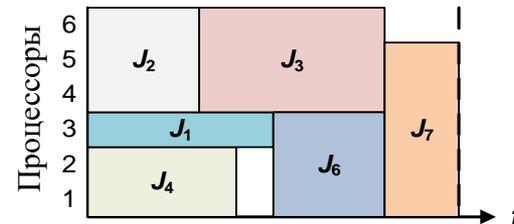
**Монозадачный режим**

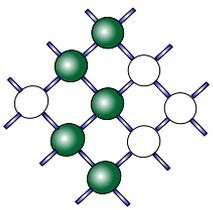
**Обслуживание потоков задач**  
Генерация подсистем в пределах ВС



Точные, эвристические, стохастические методы и алгоритмы

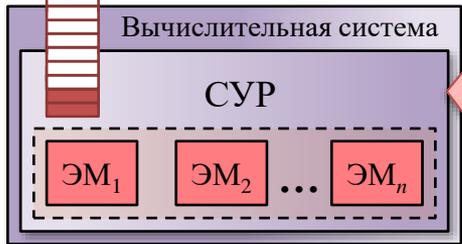
**Обработка наборов задач**  
Формирование расписаний решения параллельных задач



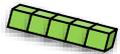


# Алгоритмы обслуживания задач на ресурсах распределенных вычислительных систем

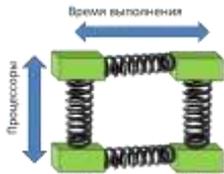
Разработаны стохастические алгоритмы формирования субоптимальных расписаний решения на распределенных вычислительных системах. Разработанные алгоритмы учитывают параметры задач (ранг и время решения).



Параллельная задача



Масштабируемая задача



— единичный ранг

Свойством масштабируемости обладают **более 80% задач**, решаемых на вычислительных системах.

Постановка задачи

$\Omega$  – область допустимых расписаний

$T(S)$  – время решения всех задач набора,  $T(S)$  – «шаг» задержка

Задача относится к целевому программированию, является NP-трудной.

Разработано семейство полиномиальных алгоритмов многокритериальной оптимизации мультипрограммного функционирования распределённых вычислительных систем в режиме обработки наборов масштабируемых задач.

Результаты экспериментального исследования показали, что отклонение суммарного времени решения задач от нижней границы целевой функции  $T(S)$  составляет 15 – 25 %.

Предложен способ описания масштабируемой задачи:

Request<sub>1</sub>[,Request<sub>2</sub>] ... [,Request<sub>i</sub>] ... [,Request<sub>n</sub>]

nodes=value[ @ppn=value][ @walltime=value][ @weight=value]

Разработано семейство эвристических алгоритмов обслуживания масштабируемых задач на распределенных ВС.

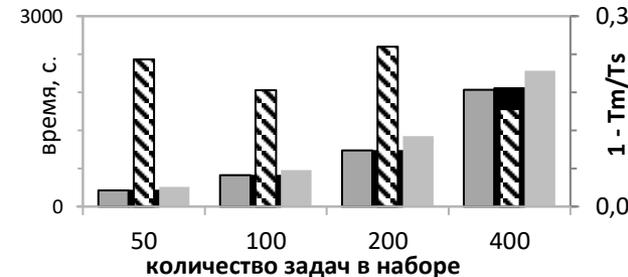
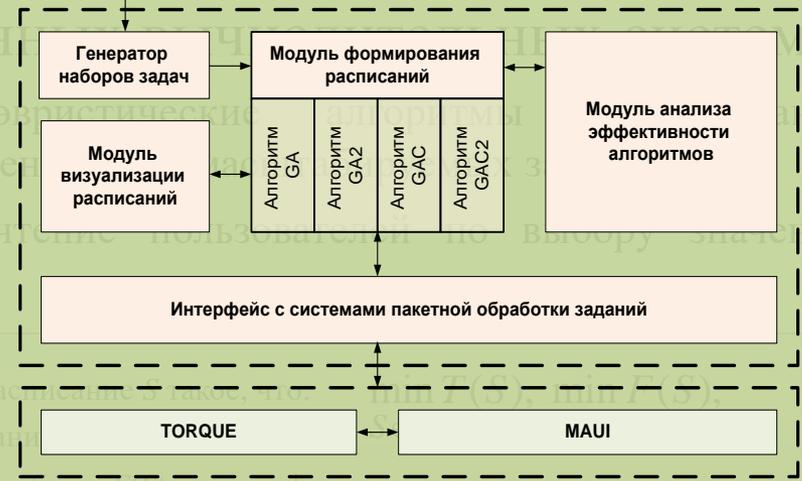
Модернизировано программное обеспечение СУР PBS Torque и планировщика MAUI.

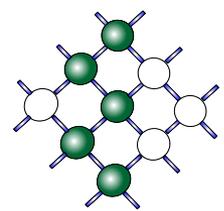
Проведено экспериментальное исследование эффективности решения масштабируемых задач.

**До 25 % снижение времени решения всех задач набора, до 15 % снижение среднего времени ожидания задачи в очереди.**

Описание ВС

## Программный пакет MOJOS

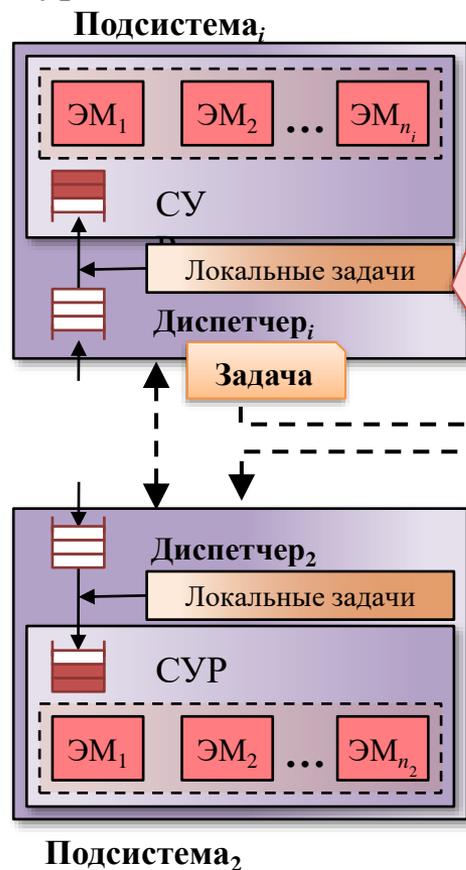




# Децентрализованная диспетчеризация параллельных программ в пространственно-распределённых мультикластерных и GRID-системах

Разработаны алгоритмы децентрализованной диспетчеризации, учитывающие текущую загрузку подсистем распределённых ВС и производительность каналов связи.

При децентрализованной диспетчеризации коллектив диспетчеров совместно принимает решение о выборе ресурсов для задач. Это позволяет достичь живучести ВС и снизить сложность поиска ресурсов для задач.



**Шаг 1.** Выбирается подсистема  $j^*$  с минимальным значением  $F(j), j \in S(j)$

$$F(j) = \begin{cases} \frac{t_j}{t_{\max}} + \frac{c_j^{-1}}{c_{\max}^{-1}} + \frac{w_j}{w_{\max}}, & \text{если } c_j < r \text{ или } q_j > 0, \\ \frac{t_j}{t_{\max}}, & \text{иначе.} \end{cases}$$

$c_j$  – количество свободных ЭМ в подсистеме  $j$ ;

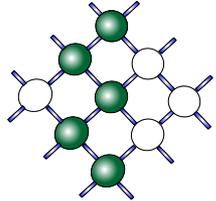
$q_j$  – количество задач в состоянии ожидания;

$w_j = q_j / n_j$  – количество задач в очереди, приходящееся на одну ЭМ;

$t_j = \sum_{l=1}^k t(h_l, j, z_l)$  – оценка времени доставки файлов задачи до подсистемы  $j$

**Шаг 2.** Задача направляется в очередь локальной СУР подсистемы  $j^*$ .

Разработанные алгоритмы (создан пакет GBroker) позволяют снизить в среднем в 1,2 раза время обслуживания задач по сравнению с централизованной диспетчеризацией (GridWay)



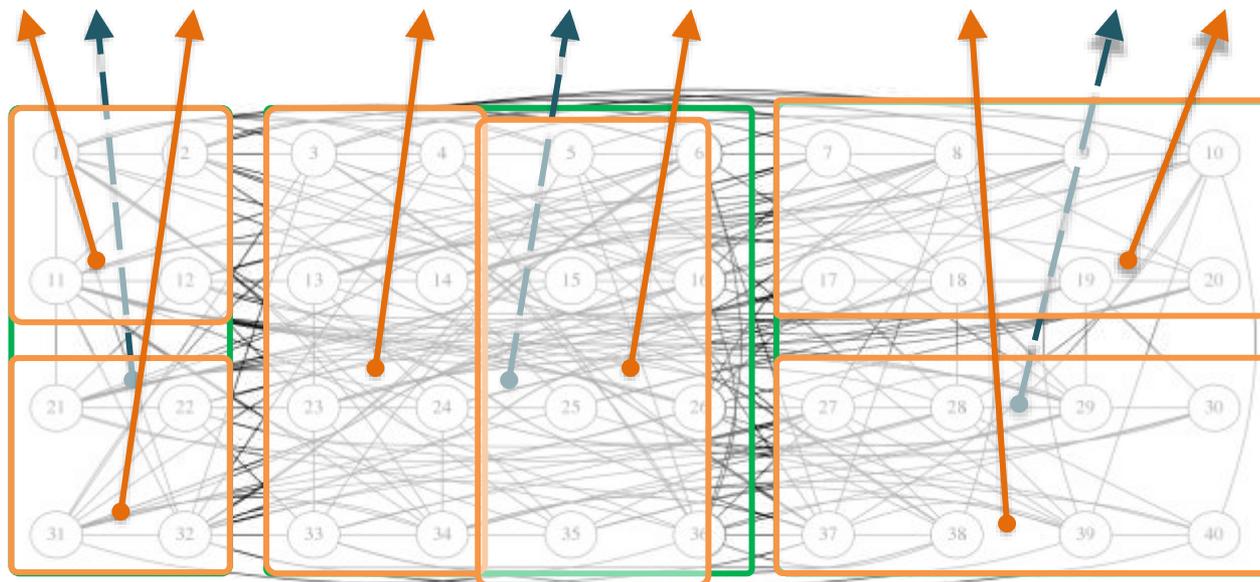
# Вложение параллельных программ в пространственно-распределённые ВС

Разработаны эффективные алгоритмы вложения в иерархические ВС параллельных программ. Алгоритмы в сравнении с известными средствами учитывают все уровни иерархической организации коммуникационных сред ВС и обеспечивают суб.мин. время выполнения дифф.-ных обменов.

В частности, предложен метод **HierarchicTaskMap**, основанный на рекурсивном разбиении графа задачи и позволяющий учитывать все коммуникационные уровни пространственно-распределённых вычислительных систем.

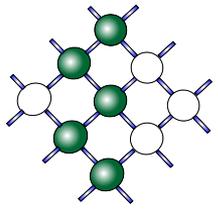


Для современных распределённых ВС систем характерны иерархическая организация и различные пропускные способности каналов связи между их ресурсами.



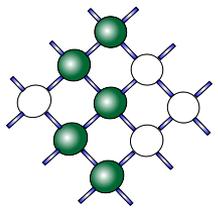
Вложение параллельной программы **The Parallel Ocean Program (POP)**,  $N = 40$  в мультикластерную ВС из трёх подсистем

Время выполнения программы уменьшилось в 1,6 раз по сравнению со стандартным вложением



# Анализ функционирования распределенных ВЫЧИСЛИТЕЛЬНЫХ СИСТЕМ

Разработка методов и построение математических моделей для расчета показателей эффективности функционирования большемасштабных распределенных вычислительных систем.



# Анализ функционирования распределенных вычислительных систем

## Объект исследования

Объектом исследования являются распределенные вычислительные системы

- Распределенная ВС представляется в виде множества элементарных машин (узлов, ядер и т.п.) соединенных коммуникационной сетью
- Все основные ресурсы являются и логически технически распределенными.

## Проблема – Надежность ВС

В силу своей большемасштабности такие ВС эффективно исследуются стохастическими методами.

*Tianhe-2*



16 000 выч.узлов, 3012000 ядер  
2 место в 50-ой ред. Top 500

*Sunway TaihuLight*



40 960 выч.узлов,  
10 649 600 ядер  
1 место в 50-ой ред.  
Top 500

*Cray XK7 Titan*

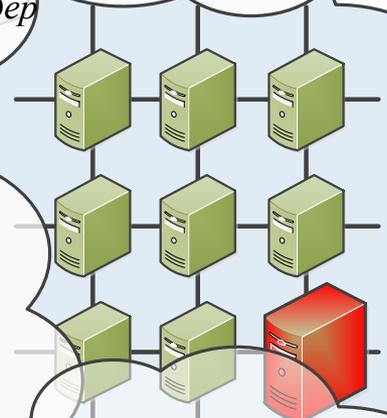


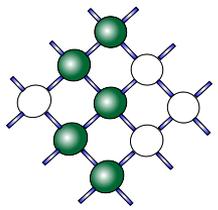
18 688 выч.узлов,  
299008 ядер  
5 место в 50-ой ред. Top 500

*IBM BlueGene/Q Sequoia*



98 304 выч.узлов,  
1 572 864 ядер  
6 место в 50-ой ред.



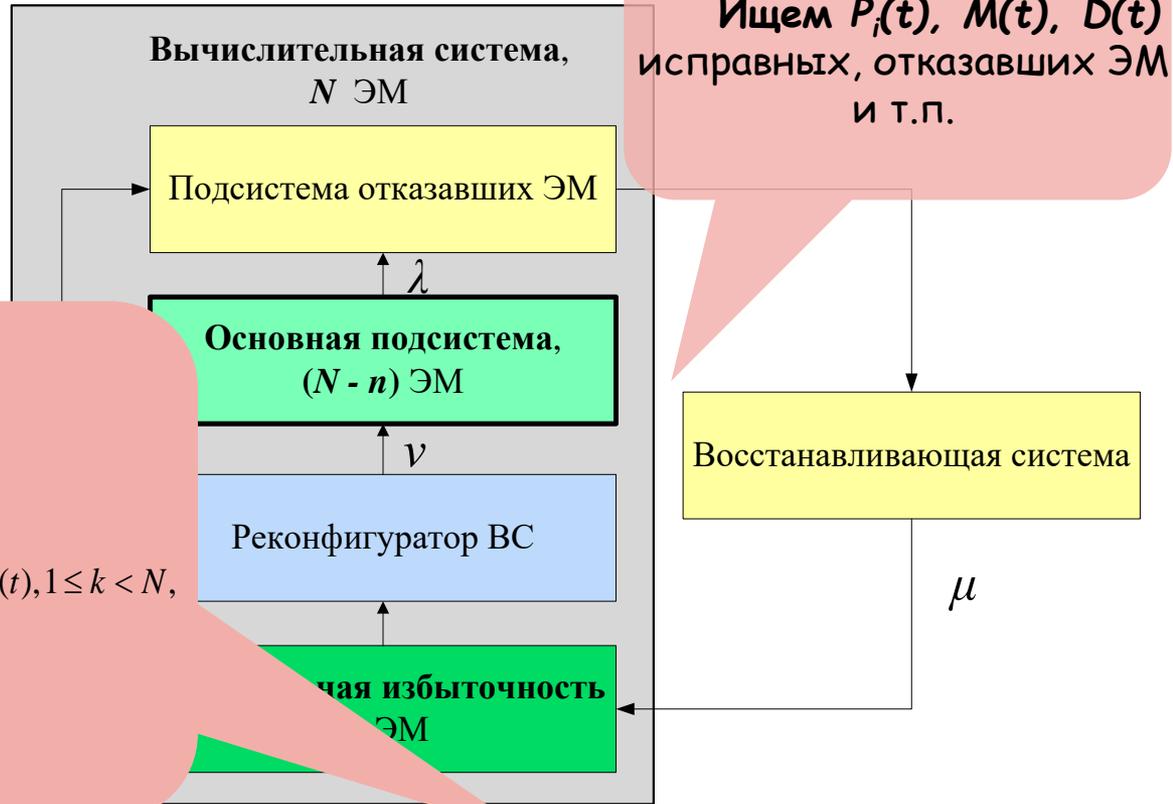


# Модель функционирования вычислительной системы

- $N$  – количество элементарных машин (ЭМ) ВС;

## Пример:

$$\begin{cases} \frac{d}{dt} P_0(t) = -\lambda_0 \cdot P_0(t) + \mu_1 \cdot P_1(t), \\ \dots \\ \frac{d}{dt} P_k(t) = -(\lambda_k + \mu_k) \cdot P_k(t) + \lambda_{k-1} \cdot P_{k-1}(t) + \mu_{k+1} \cdot P_{k+1}(t), 1 \leq k < N, \\ \dots \\ \frac{d}{dt} P_N(t) = -\mu_N \cdot P_N(t) + \lambda_{N-1} \cdot P_{N-1}(t). \end{cases}$$

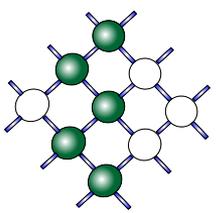


**Распределение вероятностей состояния системы  $\{P_0(i, t), P_1(i, t), \dots, P_N(i, t)\}$**

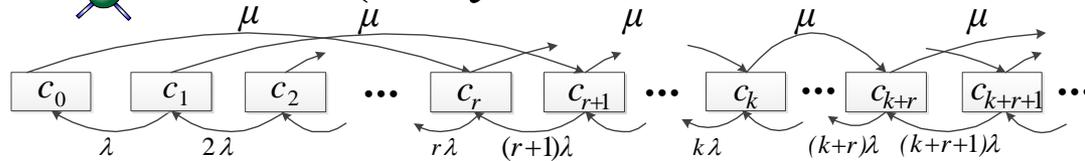
$P_j(i, t)$  – вероятность того, что в системе, начавшей функционировать в состоянии  $i \in \{0, 1, \dots, N\}$ , в момент времени  $t \geq 0$  будет  $j$  отказавших машин

1. Хорошевский В.Г. Модели анализа и организации функционирования больших распределенных вычислительных систем. // Электронное моделирование. - Киев, 2003. - Т. 25, № 6, С. 21-35.

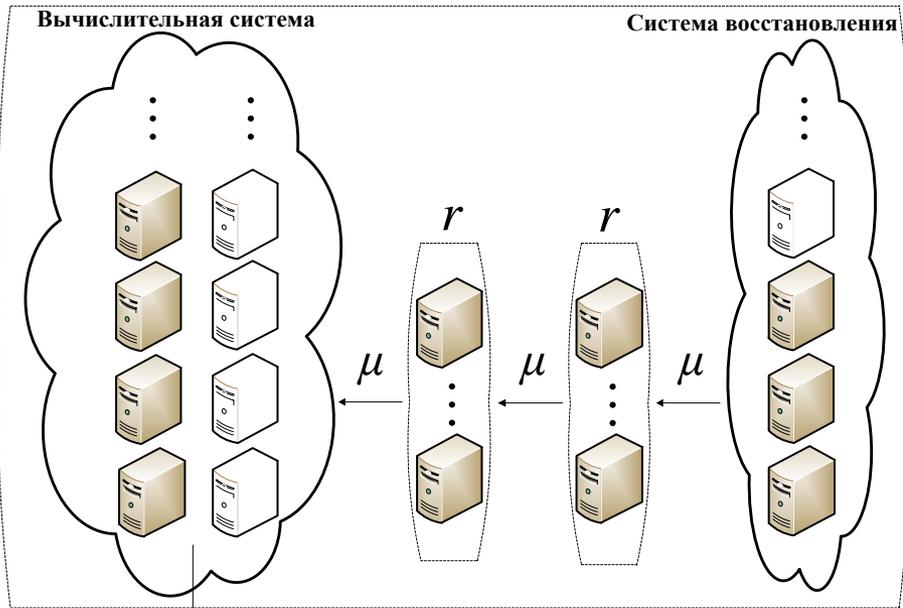
2. Хорошевский В.Г. Павский В.А., Павский К.В. Вычисление показателей живучести распределенных вычислительных систем и осуществимости решения задач // Искусственный интеллект, №4, «Наука і освіта» ДонДІШІ, 2006, С. 28 – 34.



# Модель функционирования распределенной вычислительной системы при групповом восстановлении (получена качественная и количественная оценка)



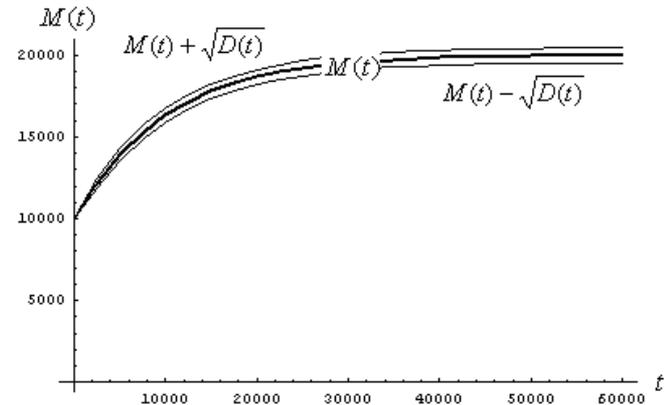
Построена математическая модель. Найдены решения для расчета мат. ожидания и дисперсии машин ВС.



$$\begin{cases} \frac{\partial}{\partial t} M(t) + \lambda M(t) = r\mu, \\ \frac{\partial}{\partial t} Q(t) + 2\lambda Q(t) = 2r\mu M(t) + r(r-1)\mu, \\ D(t) = Q(t) + M(t) - M^2(t), \end{cases}$$

$$M(0) = n, \quad D(0) = 0$$

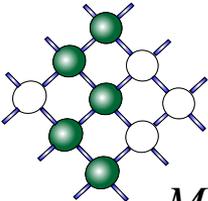
$$\begin{cases} M(t) = \frac{r\mu}{\lambda} + \left(n - \frac{r\mu}{\lambda}\right) e^{-\lambda t}, \\ D(t) = C e^{-2\lambda t} + \frac{r\mu}{\lambda} \left(\frac{r\mu}{\lambda} + 2\left(n - \frac{r\mu}{\lambda}\right) e^{-\lambda t}\right) + \frac{r(r-1)\mu}{2\lambda} + M(t) - M^2(t), \\ C = -\frac{r\mu}{\lambda} \left(2n - \frac{r\mu}{\lambda} + \frac{(r-1)}{2}\right) - n + n^2. \end{cases}$$



Математическое ожидание исправных машин  
 $\lambda = 10^{-4} \quad \mu = 0.1 \mu^{-1} \quad r = 20 \quad n = 10^4 \text{ ЭМ}$

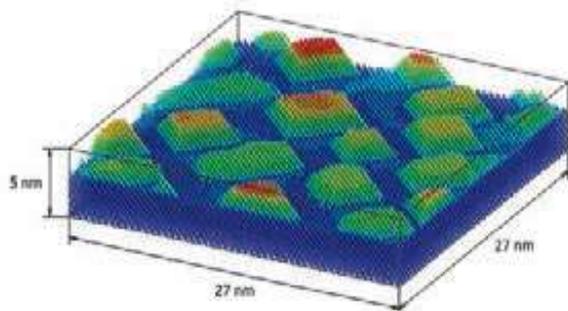
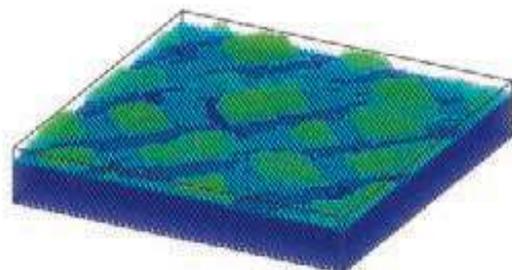
$$\begin{cases} P_0'(t) = -\mu P_0(t) + \lambda P_1(t), \\ P_k'(t) = -(\mu + k\lambda) P_k(t) + (k+1)\lambda P_{k+1}(t), \quad 0 < k < r, \\ P_k'(t) = -(\mu + k\lambda) P_k(t) + \mu P_{k-r}(t) + (k+1)\lambda P_{k+1}(t), \quad k \geq r. \end{cases}$$

$$P_n(0) = 1, \quad P_k(0) = 0, \quad k \neq n, \quad k = 0, 1, 2, \dots;$$



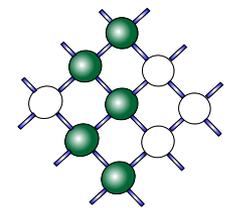
# Разработка параллельных алгоритмов моделирования гетероэпитаксиального роста

*Моделирование процесса зарождения и роста трехмерных островков Ge на Si(100)  
(Лаборатория неравновесных полупроводниковых систем)*



- Приоритетной задачей в области материаловедения является создание пространственно упорядоченных массивов полупроводниковых квантовых точек (КТ).
- Одним из методов получения пространственно упорядоченных массивов КТ является молекулярно-лучевая эпитаксия (МЛЭ) на структурированных подложках
- Механизм роста на поверхности со сложным рельефом изучен не достаточно. Поэтому актуальной проблемой является исследование зарождения и роста КТ в ямках с помощью алгоритмов моделирования данного процесса.  
(Методы МК и МД)

*Рис. Эволюция поверхности кристалла в процессе моделирования роста Ge на Si(100) в следующих условиях: температура 400° С, скорость осаждения Ge 0.1 МС/с. Количество осажденного германия: 3 МС (а), 4 МС (б), 5 МС (в). Цвет соответствует высоте рельефа поверхности*



## Актуальность

**Эпитаксия** - это закономерное нарастание одного кристаллического материала на другом, при более низких температурах, то есть ориентированный рост одного кристалла на поверхности другого (подложки).

Одним из видов эпитаксии является **гетероэпитаксия** - когда растущий слой отличается по химическому составу от вещества подложки.

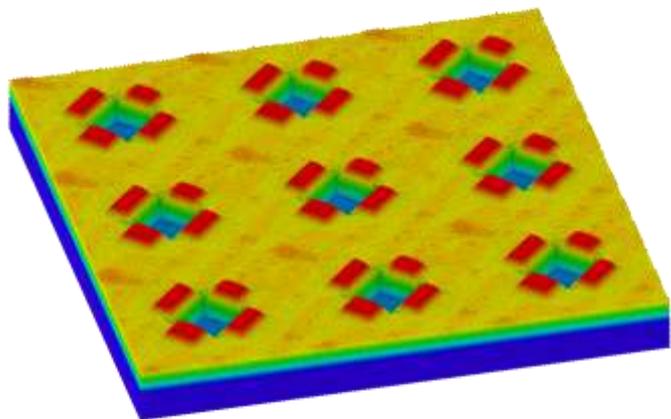


Рис. 1 - Ямки и зарождение  
Квантовых точек

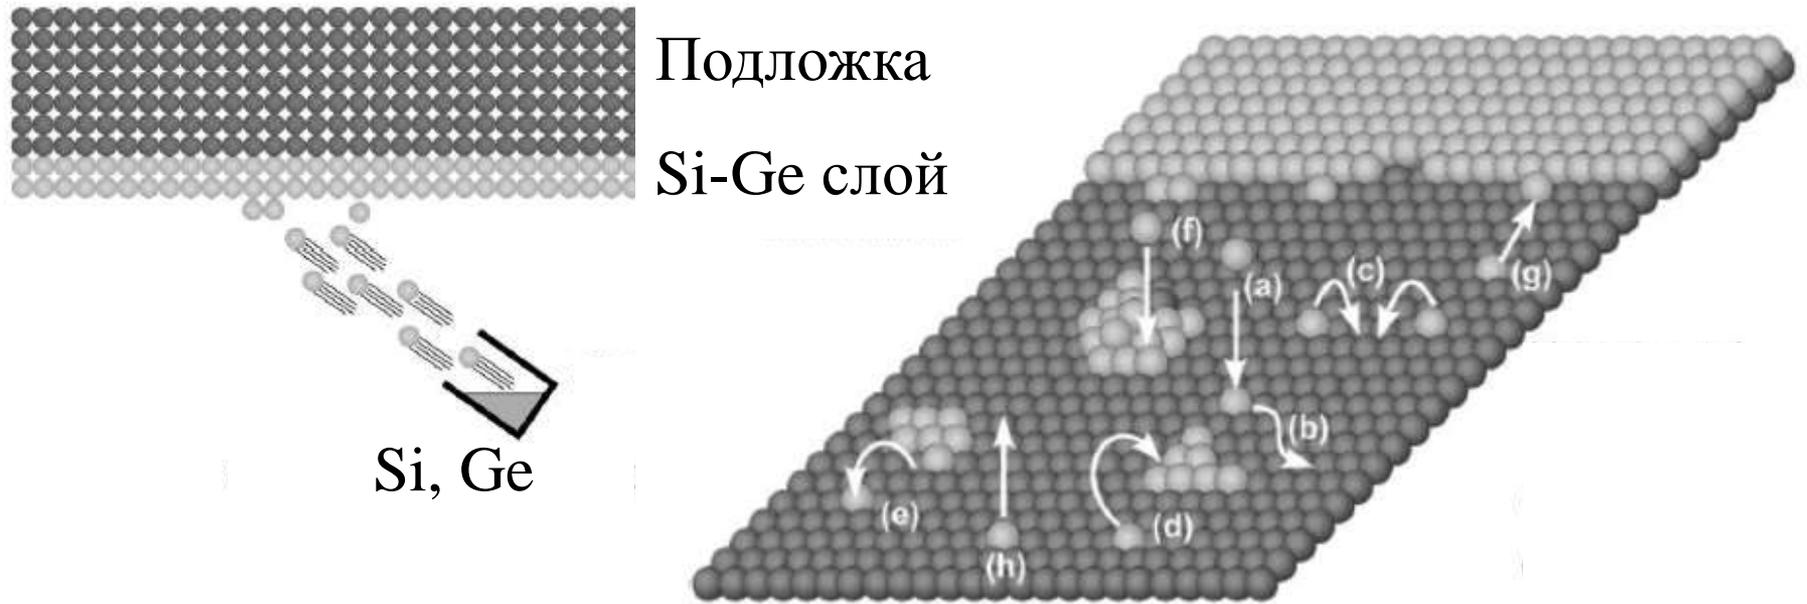
Например, для моделирования процесса гетероэпитаксии [1] (**ИФП СО РАН**) на подложке размером  $38 \times 38 \times 8$  нм<sup>3</sup> (~586 тыс. атомов) требуется **2616 ч (~109 суток)** на узле кластера **ИВЦ НГУ**.

Следовательно, **актуальной** является **разработка параллельных алгоритмов и программ для моделирования гетероэпитаксии.**

[1] Rudin S.A., Zinovyev V.A., Smagina Zh.V., Novikov P.L., Nenashev A.V., Pavsky K.V. Groups of Ge nanoislands grown outside pits on pit-patterned Si substrates // *Journal of Crystal Growth*, Available online 12 June 2022, 126763 In Press, Journal Pre-proof <https://doi.org/10.1016/j.jcrysgro.2022.126763> <https://www.sciencedirect.com/science/article/pii/S0022024822002512?via%3Dihub>

# Молекулярно-лучевая эпитаксия

## Метод Монте -Карло



(a) осаждение на поверхность

(b) диффузия по поверхности

(c) образование островка

(d) присоединение атомов к островку

(e) отсоединение атомов от островка

(f) осаждение на островок

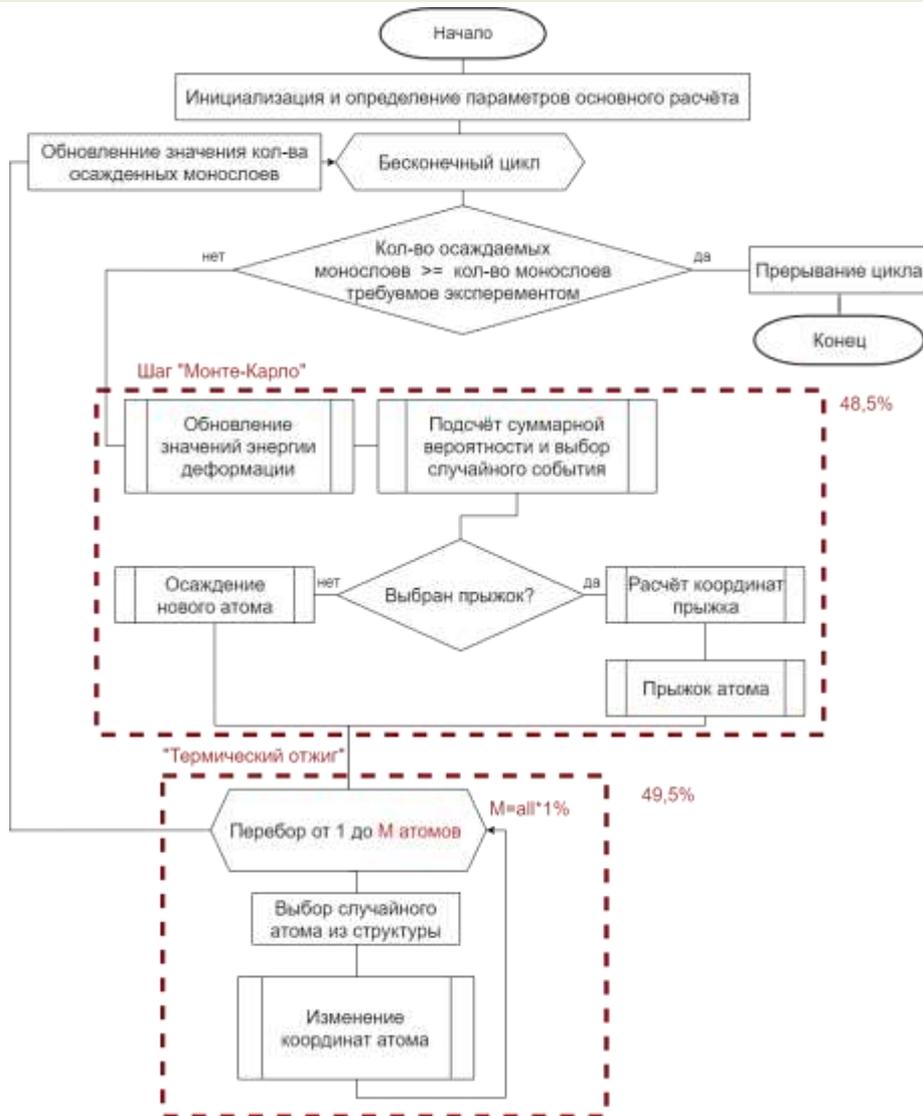
(g) присоединение к ступени

(h) десорбция с поверхности

*Bert Voigtländer. Fundamental processes in Si/Si and Ge/Si epitaxy studied by scanning tunneling microscopy during growth // Surface Science Reports 2001. V. 43, Issues 5-8, P. 127-254*

# Монте-Карло моделирование гетероэпитаксии

## Основной цикл



Обновление значения энергии деформации {

```
...
#pragma omp parallel for private(dir)
reduction(+:Bx, By, Bz)
```

```
...
#pragma omp parallel for private(dir)
```

}  
Вычисление суммарной вероятности прыжков атомов {

```
...
#pragma omp parallel for private(x,y,z)
reduction(+:real_sum)
```

```
...
#pragma omp parallel for private(dir)
reduction(+:E_a)
```

```
...
}
```

Прыжок атома {

```
...
#pragma omp parallel for private(n)
shared(bad_jump)
```

```
...
#pragma omp parallel for private(dir)
reduction(+:Bx, By, Bz)
```

```
...
#pragma omp critical v_ochered_Edef
```

```
...
}
```

Осаждение атома {

```
...
#pragma omp parallel private(dir)
```

```
...
#pragma omp parallel for private(dir)
reduction(+:Bx, By, Bz)
```

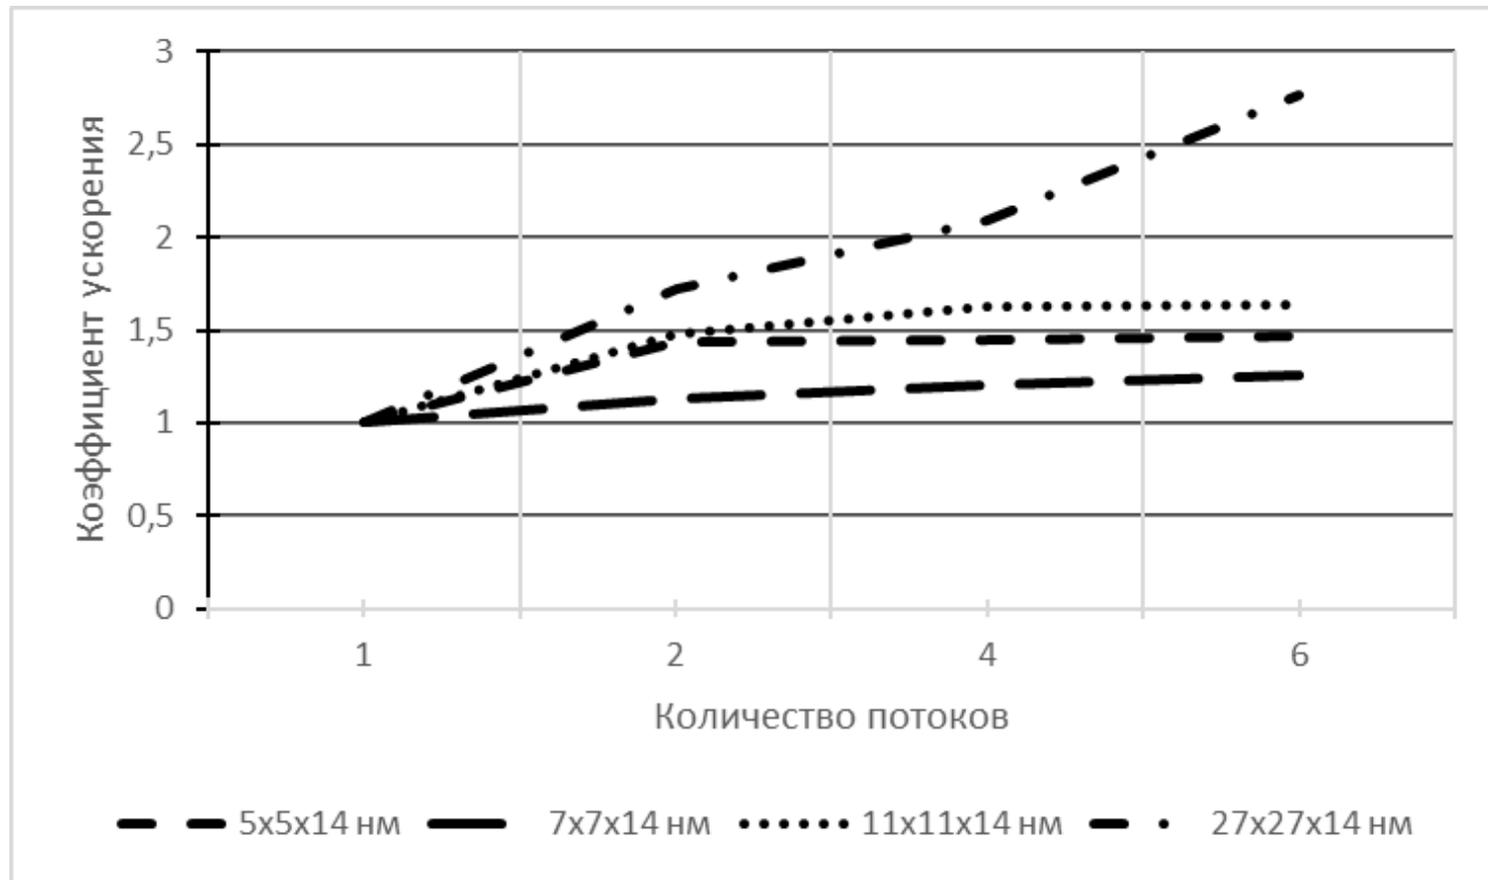
```
...
#pragma omp critical v_ochered_Edef
```

```
...
#pragma omp parallel for private(dir)
reduction(+:n_jumps)
```

```
...
}
```

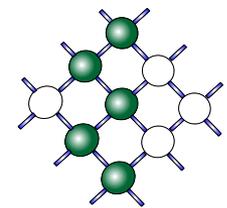
# Эффективность распараллеливания

Моделирование проводилось на вычислительном узле с параметрами: **8-ядерный процессор Intel Core i7-9700K** с тактовой частотой **3.60 ГГц**, **32 ГБ ОЗУ**

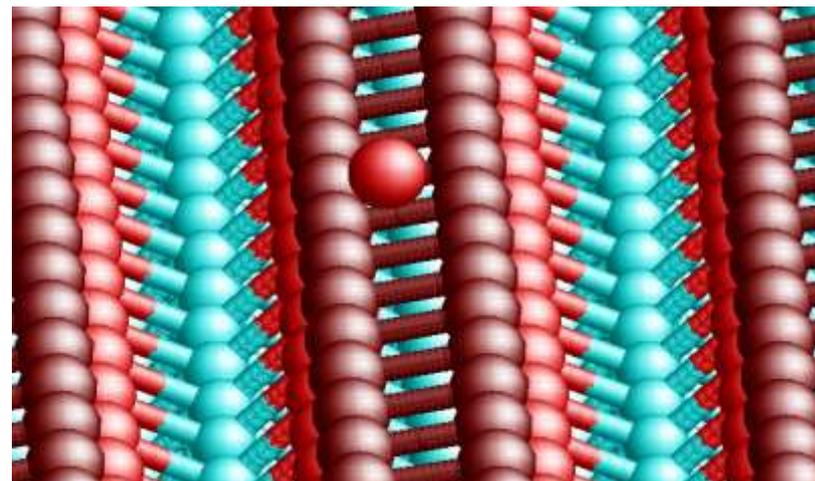
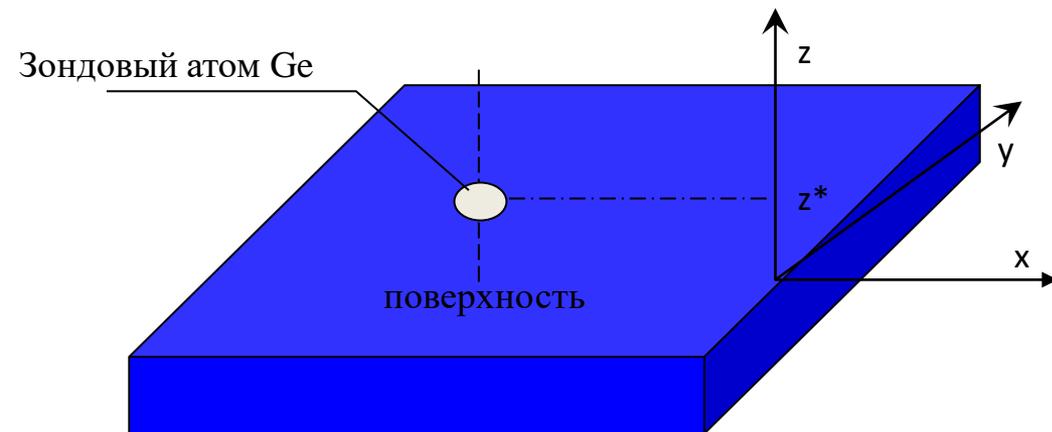


Моделирование осаждения **4 МС (~0,54 нм)** Ge  
на подложки Si различных размеров при **500°C**

$K_n = T_1/T_n$ , где  $T_n$  – время выполнения программы при  $n$  потоках.



# Расчет потенциального рельефа Метод молекулярной динамики



- Зондовый атом Ge помещается в точку  $(x, y)$  над поверхностью
- Зондовый атом имеет только одну степень свободы вдоль  $z$
- Имитируется релаксация системы, зондовый атом находит равновесное положение  $z^*$
- Вычисляется энергия зондового атома  $U(z^*)$  в точке  $(x, y, z^*)$
- Потенциальный рельеф строится путем сканирования по области  $x$ - $y$

# Расчет методом молекулярной динамики потенциального рельефа структурированных подложек (расчеты методом молекулярной динамики)

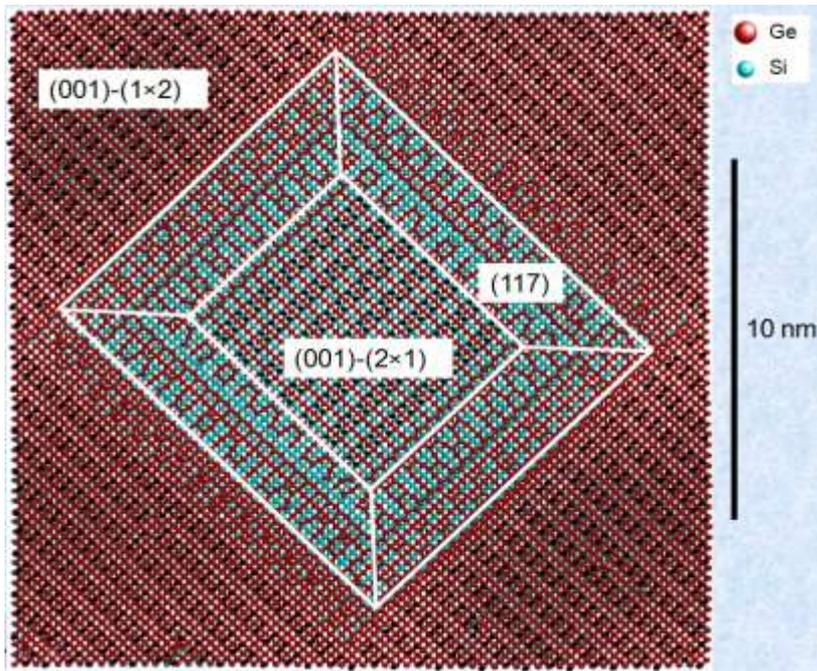


Рис. 1. Моделируемая структура с ямкой в форме перевернутой усеченной пирамиды (вид сверху). Атомы Si показаны голубым цветом, Ge - красным, Ge в димерах - черным. Белыми контурами отмечены грани усеченной пирамиды.

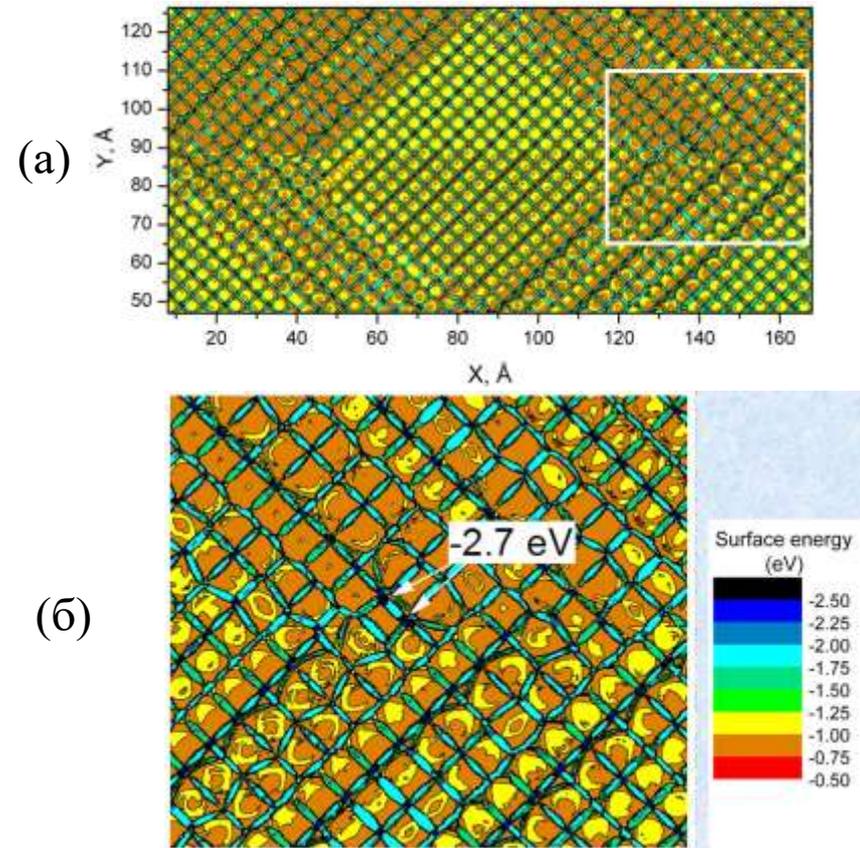


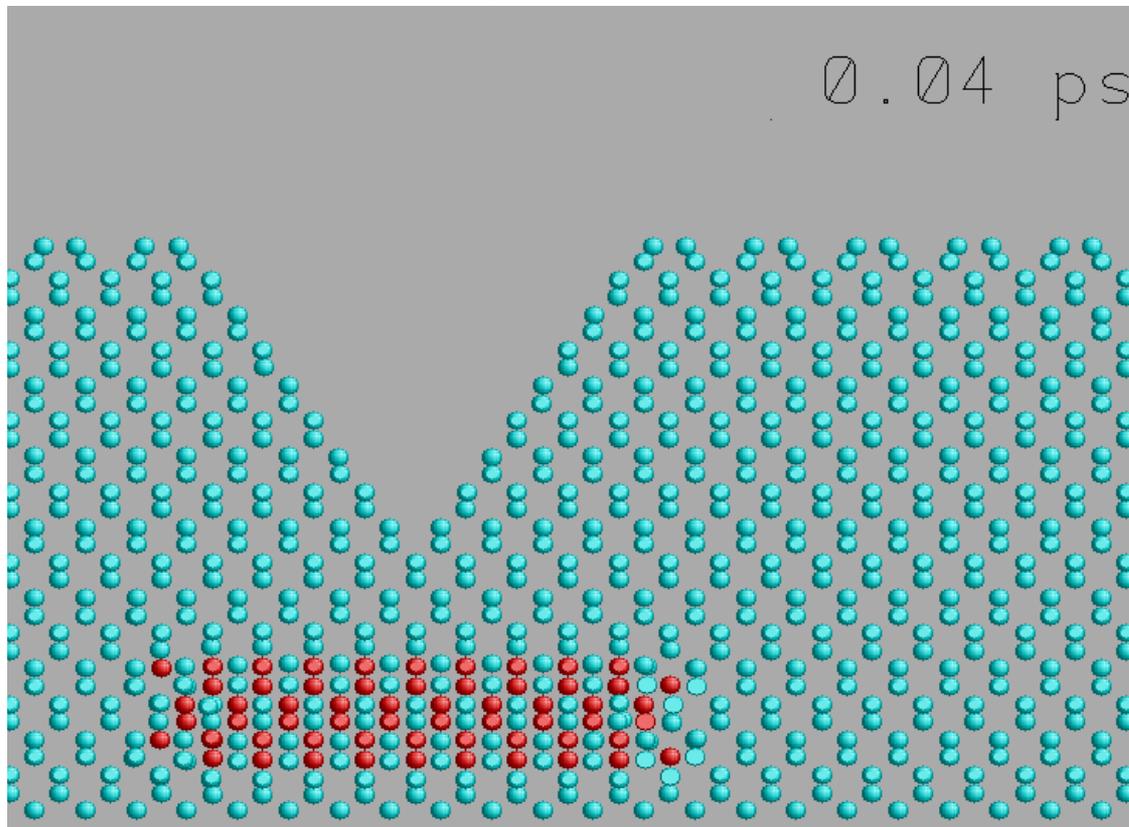
Рис.2. (а) Энергетическая поверхность моделируемой структуры. (б) увеличенный фрагмент энергетической поверхности в области, отмеченной белым контуром на рис. 2 (а).

Зондовый атом приближается к подложке на расстояние характерного межатомного взаимодействия и для полной системы решается уравнение движения на интервале времени  $2 \cdot 10^{-12}$  с. Поверхностная энергия определяется как энергия зондового атома в конечном (равновесном) положении.

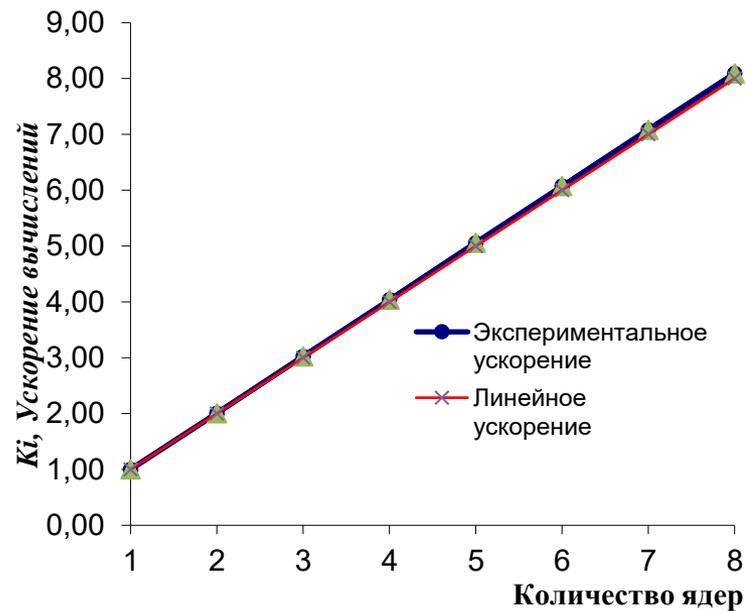
**Энергетическая поверхность строится с помощью зондового атома сканированием поверхности структуры в пределах исследуемой области.**

# Изменение деформаций в структурированной подложке Si, обусловленные введенными междоузельными атомами Ge (расчеты методом молекулярной динамики)

А.В. Двуреченский, П.Л. Новиков, К.В. Павский, Ж.В. Смагина



Поперечное сечение канавки в моделируемой структуре.

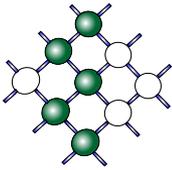


Ускорение параллельной программы.

$$K_i = T_1/T_i$$

$T_i$  – время исполнения программы на  $i$  ядрах.

Ориентация стенки канавки	Деформация (%) Концентрация междоузельных атомов		Вклад междоузельных атомов (%)
	$10^{20} \text{ см}^{-3}$	0	
<b>(111)</b>	-5.35	-0.74	-4.61



# Программная реализация отказоустойчивого расчета потенциального рельефа



**СПАСИБО ЗА ВНИМАНИЕ**