



**neoSYCL**  
**SX-Aurora TSUBASAのための**  
**軽量SYCL実装**

2022年4月15日  
PCCC HPC-OSS部会ワークショップ  
「高性能クラスタ・プログラミング最前線」

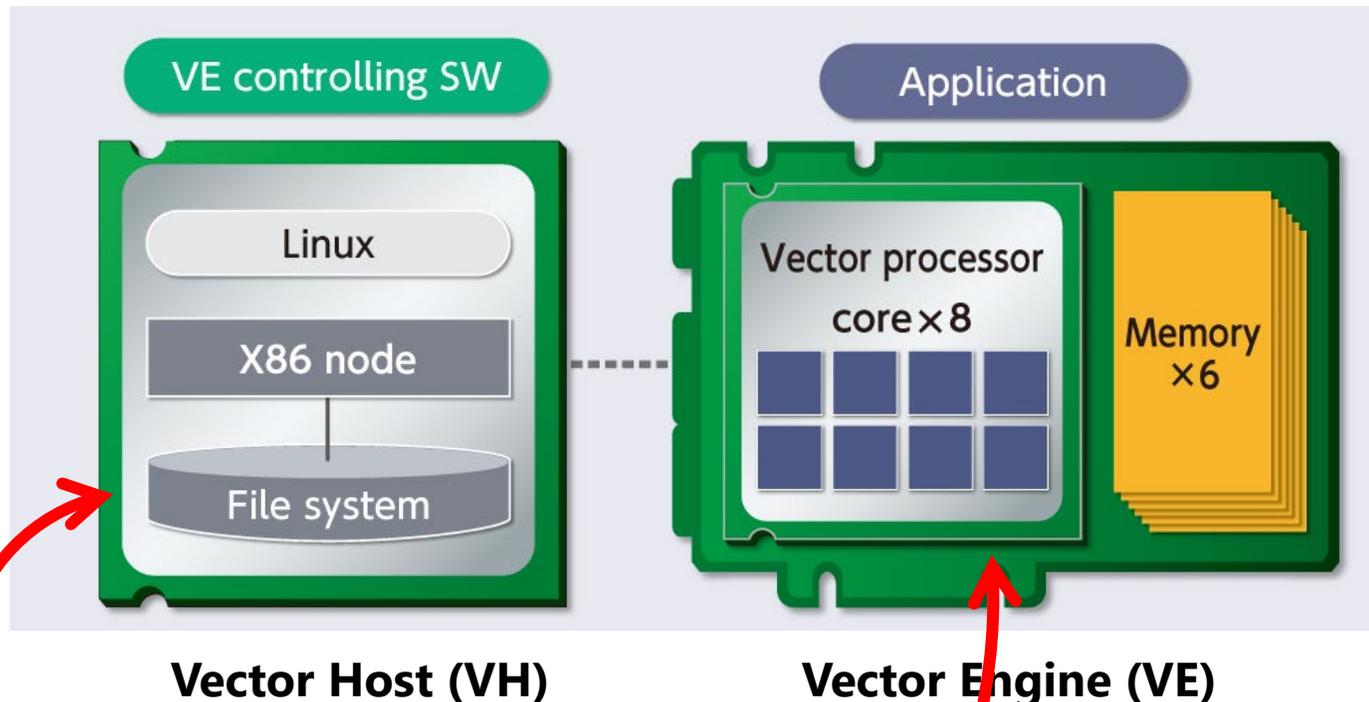
東北大学サイバーサイエンスセンター  
滝沢 寛之

<takizawa@tohoku.ac.jp>

# もくじ

- 背景と目的
- SX-Aurora TSUBASA向けSYCL実装
- 性能評価
- まとめと今後の展望

# 背景 ～ ヘテロ構成のベクトルシステム ～



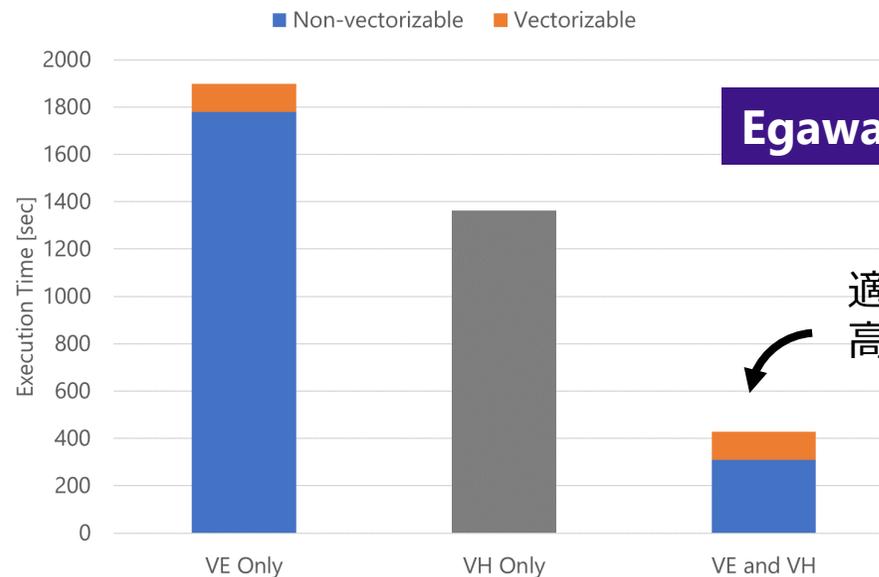
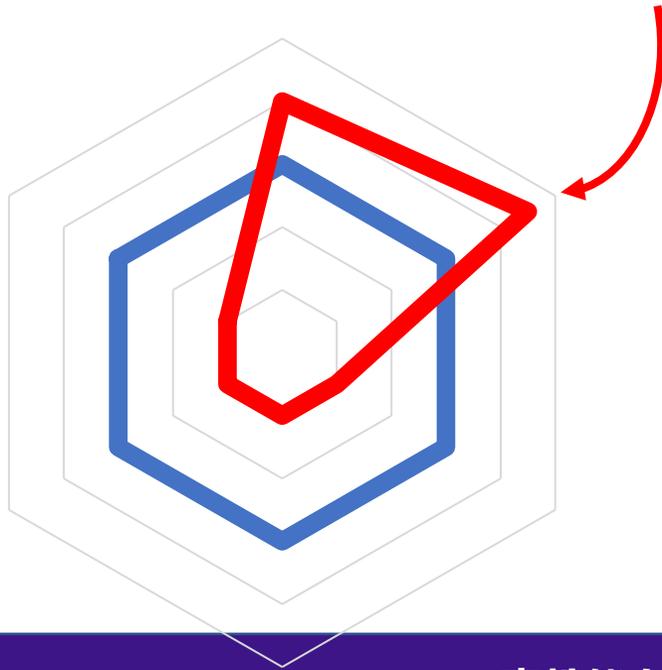
東北大学のスパコンAOBA  
NEC SX-Aurora TSUBASAを  
中核とするHPCシステム

```
$ gcc matmul.c -o matmul
$ ./matmul

$ ncc matmul.c -o matmul
$ ./matmul
```

# 動機 ～ 適材適所の必要性 ～

- **Vector Host** と **Vector Engine** は両方とも
  - 汎用プロセッサ (単なるアクセラレータではない)
    - 標準的なプログラミング言語を単独で実行可能 (C/C++/Fortran etc)
  - 異なる性能特性
    - **ベクトル向きの処理であれば VEは高性能を発揮可能**



Egawa et al. (PBMS2020)

適材適所の利用によって  
高い実行性能を達成

# Vector Engine Offloading (VEO)

- カーネル実行をVEにオフロードするための低レベルな専用API

## Main program for VH

```
#include <ve_offload.h>
int main()
{
    /* Load "vehello" on VE node 0 */
    struct veo_proc_handle *proc = veo_proc_create(0);
    uint64_t handle = veo_load_library(proc, "./libvehello.so");
    struct veo_thr_ctxt *ctx = veo_context_open(proc);
    struct veo_args *argp = veo_args_alloc();
    uint64_t id = veo_call_async_by_name(ctx, handle, "hello", argp);
    uint64_t retval;
    veo_call_wait_result(ctx, id, &retval);
    veo_args_free(argp);
    veo_context_close(ctx);
    veo_proc_destroy(proc);
    return 0;
}
```

## kernel program for VE

```
#include <stdio.h>
#include <stdint.h>
uint64_t hello()
{
    printf("Hello, world\n");
    return 0;
}
```

このコードをコンパイルして  
共有オブジェクト

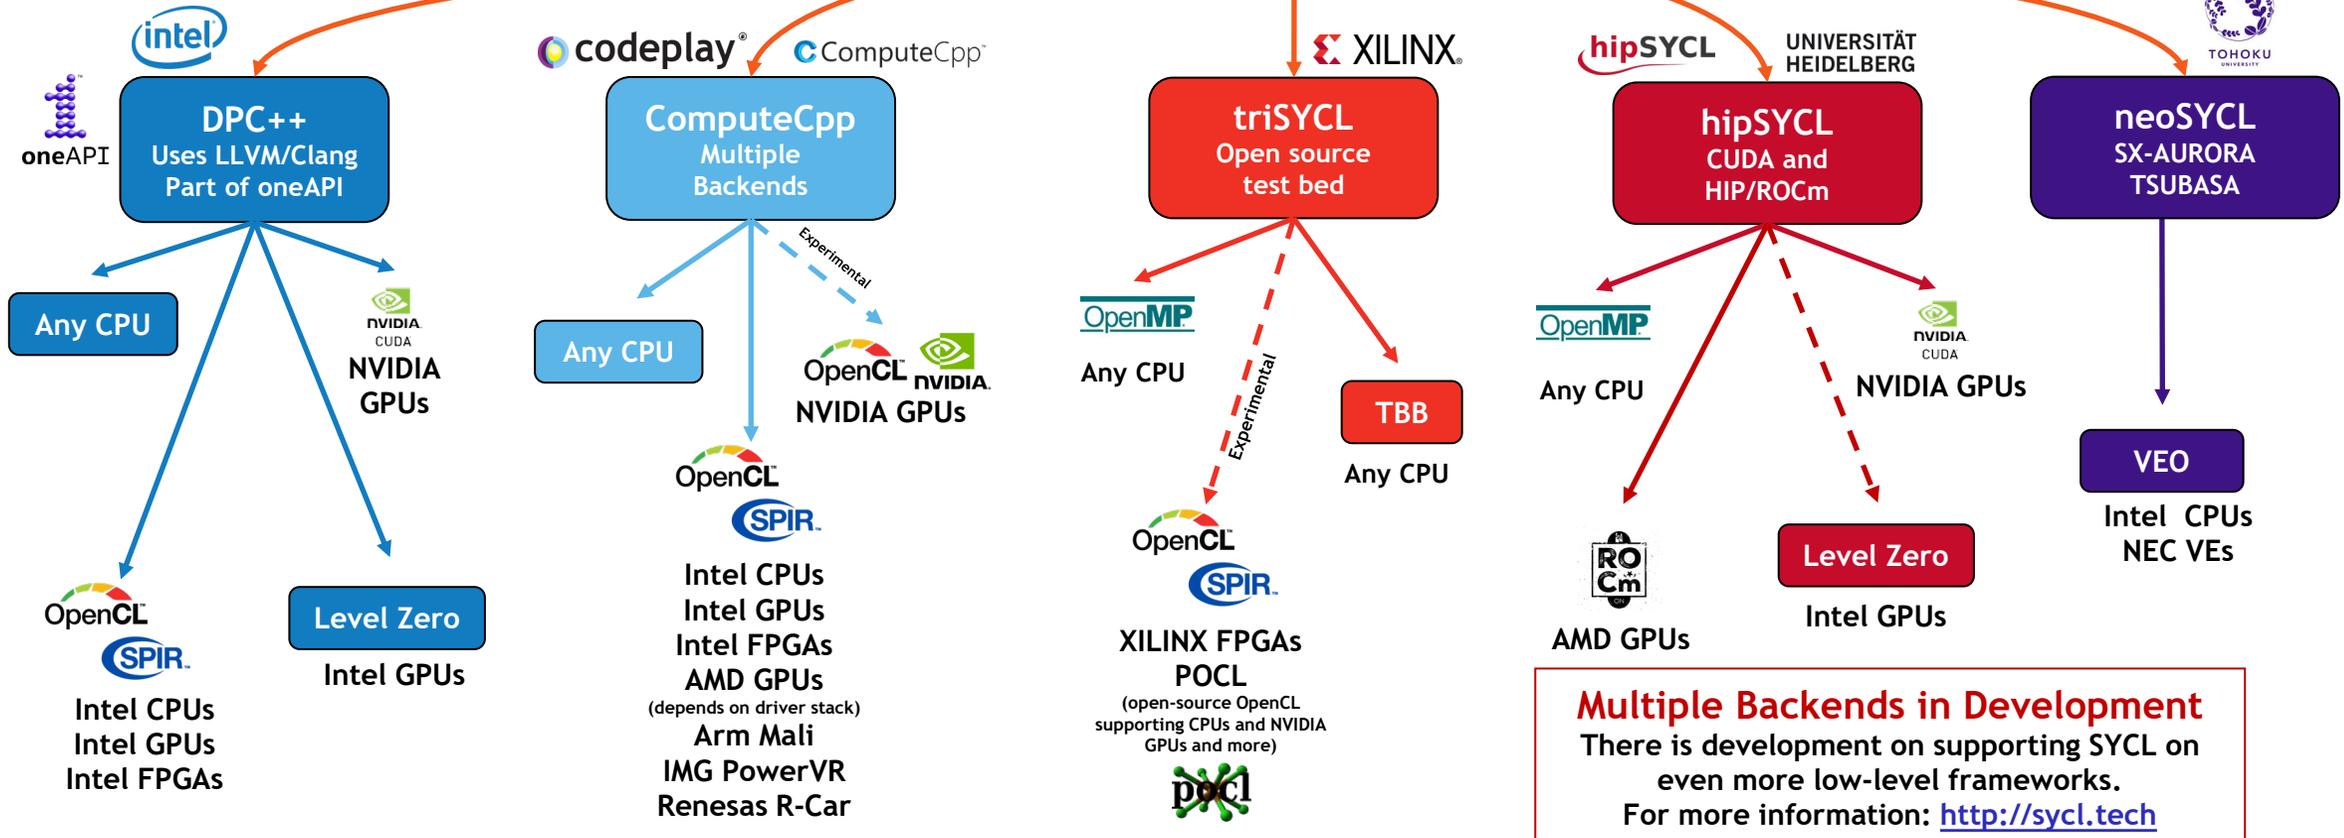
**./libvehello.so**  
として準備

SX-Aurora TSUBASA専用のアプリになってしまうことが問題

# SYCL Implementations in Development (2021/04/27)

SYCL, OpenCL and SPIR-V, as open industry standards, enable flexible integration and deployment of multiple acceleration technologies

SYCL enables Khronos to influence ISO C++ to (eventually) support heterogeneous compute



**Multiple Backends in Development**  
 There is development on supporting SYCL on even more low-level frameworks.  
 For more information: <http://sycl.tech>

# neoSYCL

- VEOをバックエンドとして利用するSYCLインタフェースの実装
  - Kernel Outlining

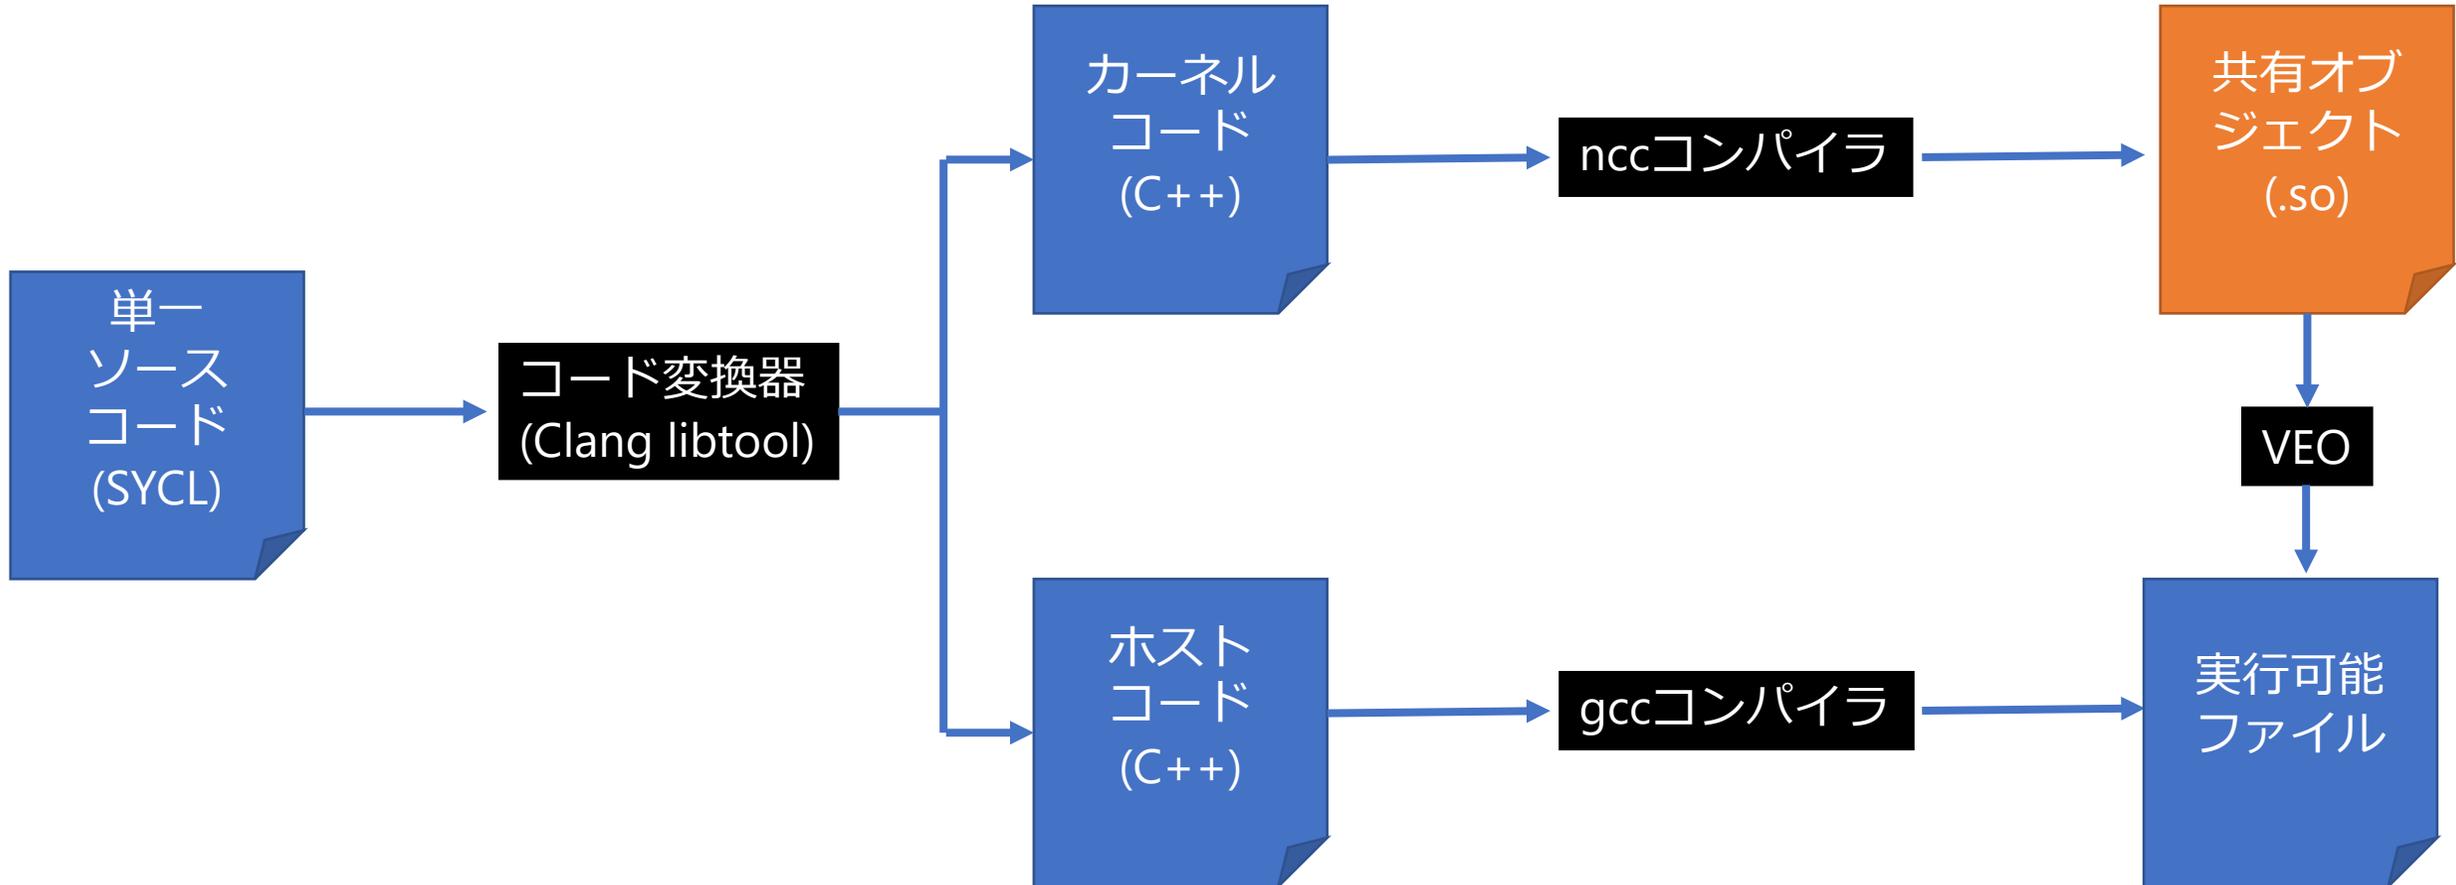
```
queue.submit([&](handler &cgh) {
  auto ka = buf_a.template get_access<access::mode::write>(cgh);
  auto kb = buf_b.template get_access<access::mode::read>(cgh);
  auto kc = buf_c.template get_access<access::mode::read>(cgh);
  cgh.parallel_for<class triad_kernel>(range<1>(array_size), [=](const id<1> &i) {
    ka[i] = kb[i] + scalar * kc[i];
  });
});
```

カーネル部分 (functor) を分離して関数内のループに変換  
→ VEOを使うことで、カーネル部分だけをVEにオフロード実行可能

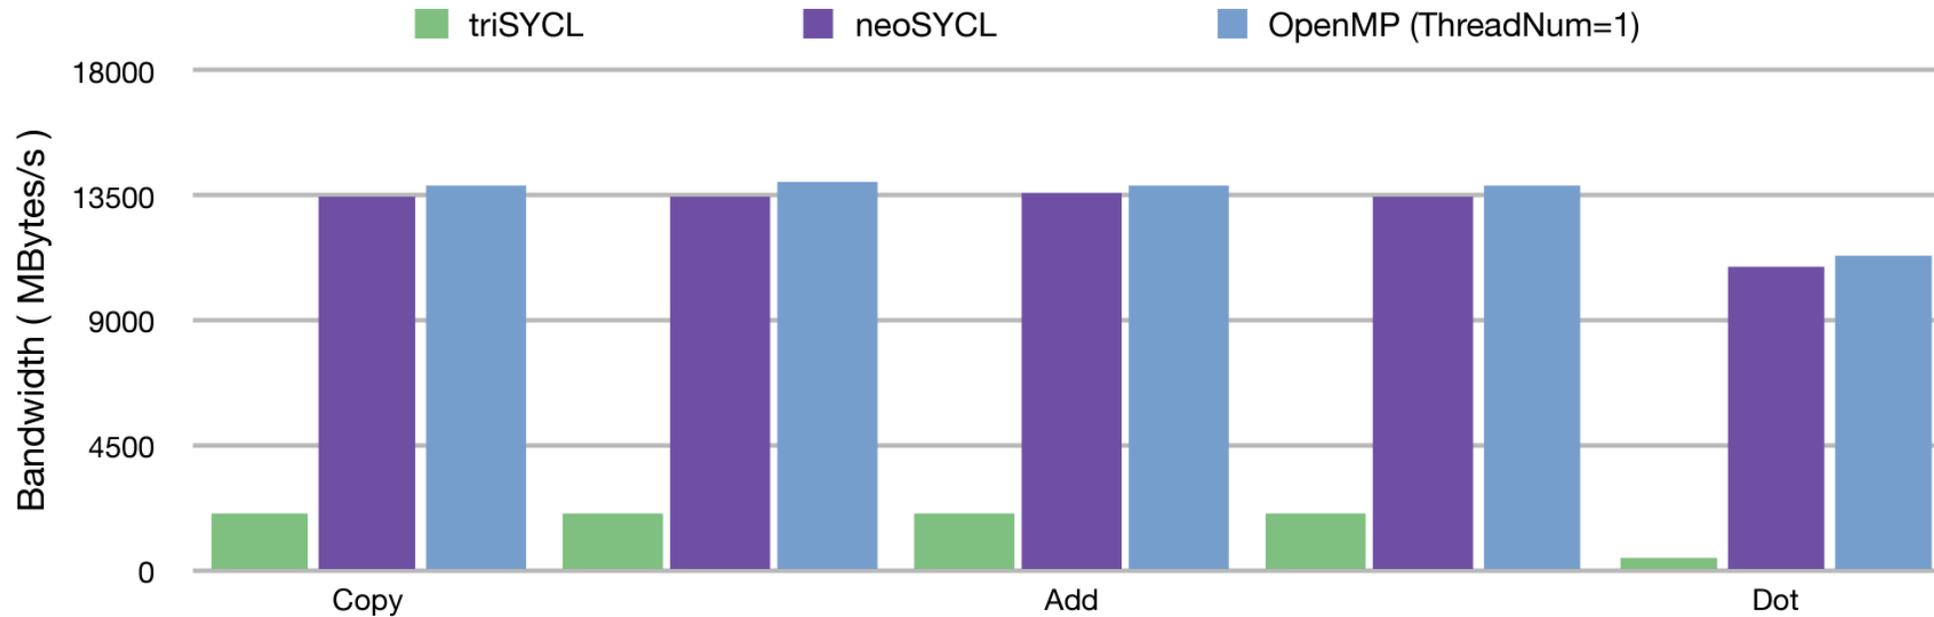
```
int triad_kernel(double *ka, double *kb, double *kc, int N) {
  for (int i = 0; i < N; i++) {
    ka[i] = kb[i] + 0.4 * kc[i];
  }
  return 0;
}
```

コード変換器以外はヘッダファイルとして実装  
= SYCLインタフェースを提供するための簡易実装

# コンパイルの流れ



# 他のSYCL実装との比較



- GPU-STREAM (CPU実行)

- 1スレッド実行での性能比較

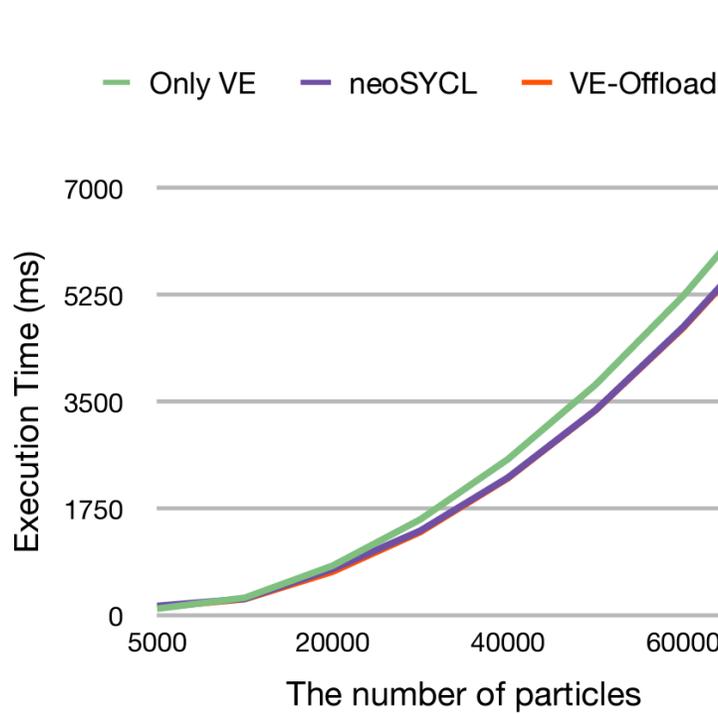
- OpenMP実装とneoSYCL実装の性能差は平均1.6%程度
    - triSYCLが使っているBoostの多次元配列がメモリ確保とデータコピーを多く実行

# N-bodyによる評価

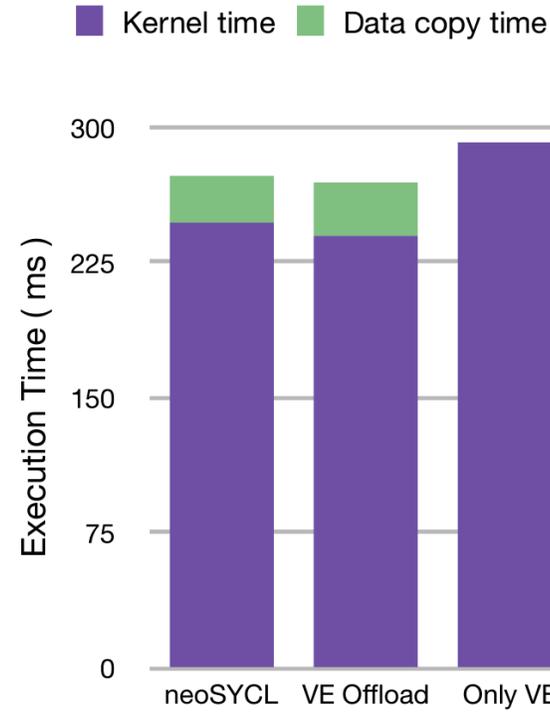
- 2つのループ (速度と位置)をそれぞれカーネルとしてオフロード
  - カーネル以外の部分はVHで実行 (VHの方が高性能)

```
for (int i = 0; i < nBodies; i++) {  
    float Fx = 0.0f;  
    float Fy = 0.0f;                                loop-1  
    float Fz = 0.0f;  
    for (int j = 0; j < nBodies; j++) {  
        ...  
    }  
    p[i].vx += delta * Fx;  
    p[i].vy += delta * Fy;  
    p[i].vz += delta * Fz;  
}  
for (int i = 0; i < nBodies; i++) {  
    p[i].x += p[i].vx * delta;  
    p[i].y += p[i].vy * delta;                                loop-2  
    p[i].z += p[i].vz * delta;  
}
```

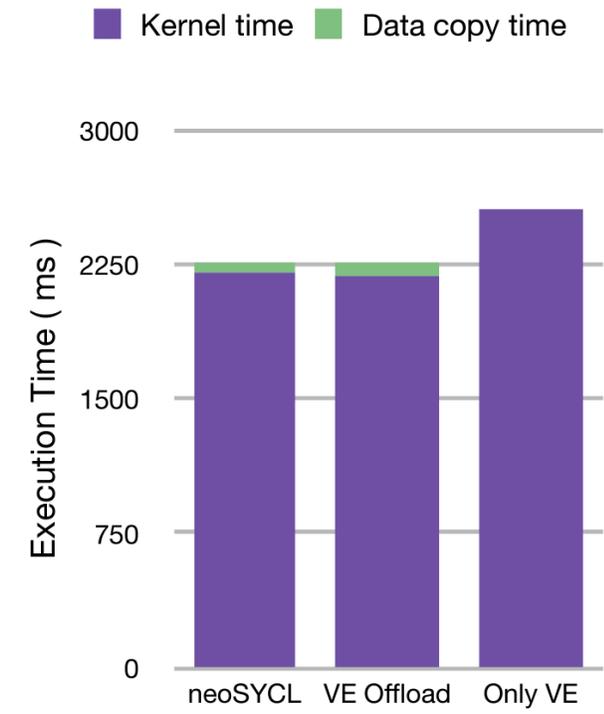
# N-bodyによる評価結果



データサイズと実行時間



データサイズ 10,000

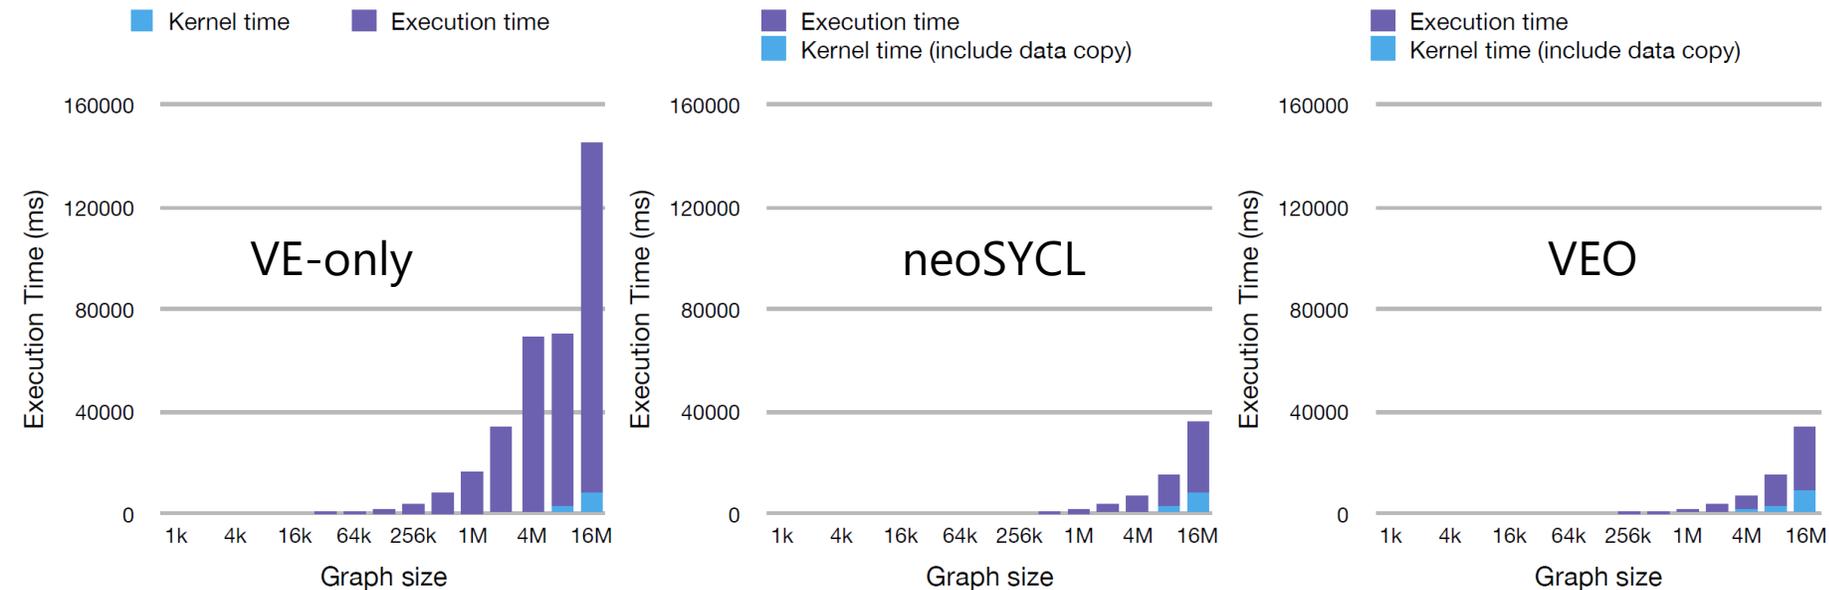


データサイズ 40,000

- データ転送時間を考慮してもオフロードしたほうが高性能
  - いずれの実装でもカーネル実行時間が支配的
  - VEO(低レベルAPI)とneoSYCLはほぼ同等の性能 (性能差は1.7%程度)

# BFS(Rodinia)による評価結果

- 初期化部分がベクトルに不向きな実装のためオフロードが効果的



SYCLインタフェースによりコード複雑さを低減可能

Applicaton	VERSION	NLOC	AvgCCN	Avg.token
STREAM	SYCL	148	1.2	96
	VE-Offload	296	3.8	159.7
N-body	SYCL	86	2.7	233.3
	VE-Offload	166	5	240.2
	Origin	66	3.3	173.7
BFS	SYCL	133	4.5	248
	VE-Offload	225	7.4	302
	Origin	116	4.5	196.2

# 独自ベンチマーク集の作成

- **VEO-SYCL-Bench** <https://github.com/Tohoku-University-Takizawa-Lab/veo-sycl-bench>
  - SYCL-Bench (Lal et al.@Euro-Par 2020)が動かない(?)
    - DPC++でもneoSYCLでもコンパイルエラー
  - 抽象化によるオーバヘッドの評価にはVEO版も必要

```

1 void setup() {
2     input1.resize(args.problem_size);
3     input2.resize(args.problem_size);
4     output.resize(args.problem_size);
5     for (size_t i = 0; i < args.problem_size; i++) {
6         input1[i] = static_cast<T>(i);
7         input2[i] = static_cast<T>(i);
8         output[i] = static_cast<T>(0);
9     }
10    input1_buf.initialize(args.device_queue, input1.data(), s::range<1>(args.problem_size));
11    input2_buf.initialize(args.device_queue, input2.data(), s::range<1>(args.problem_size));
12    output_buf.initialize(args.device_queue, output.data(), s::range<1>(args.problem_size));
13 }
14 void run(std::vector<cl::sycl::event>& events) {
15     events.push_back(args.device_queue.submit(
16         [&](cl::sycl::handler& cgh) {
17             auto in1 = input1_buf.template get_access<s::access::mode::read>(cgh);
18             auto in2 = input2_buf.template get_access<s::access::mode::read>(cgh);
19             auto out = output_buf.template get_access<s::access::mode::read_write>(cgh);
20             cl::sycl::range<1> ndrangel(args.problem_size);
21             cgh.parallel_for<class VecAddKernel<T>>(ndrangel,
22                 [=](cl::sycl::id<1> gid) {
23                     out[gid] = in1[gid] + in2[gid];
24                 });
25         });
26 }

```

SYCL-Bench's vec\_add

```

1 int main(int argc, char** argv) {
2     accelerator_selector as;
3     queue q(as);
4     vector<float> input1(LENGTH, 0);
5     vector<float> input2(LENGTH, 0);
6     vector<float> output(LENGTH, 0);
7     for (size_t i = 0; i < LENGTH; i++) {
8         input1[i] = static_cast<float>(i);
9         input2[i] = static_cast<float>(i);
10        output[i] = static_cast<float>(0);
11    }
12    buffer<float> input1_buf(input1.data(), range<1>(LENGTH));
13    buffer<float> input2_buf(input2.data(), range<1>(LENGTH));
14    buffer<float> output_buf(output.data(), range<1>(LENGTH));
15    q.submit([&](handler& cgh) {
16        auto in1 = input1_buf.template get_access<access::mode::read>(cgh);
17        auto in2 = input2_buf.template get_access<access::mode::read>(cgh);
18        auto out = output_buf.template get_access<access::mode::read_write>(cgh);
19        cgh.parallel_for<class VecAddKernel>(range<1>(LENGTH), [=](id<1> gid) {
20            out[gid] = in1[gid] + in2[gid];
21        });
22    });
23    q.wait();
24    return 0;
25 }

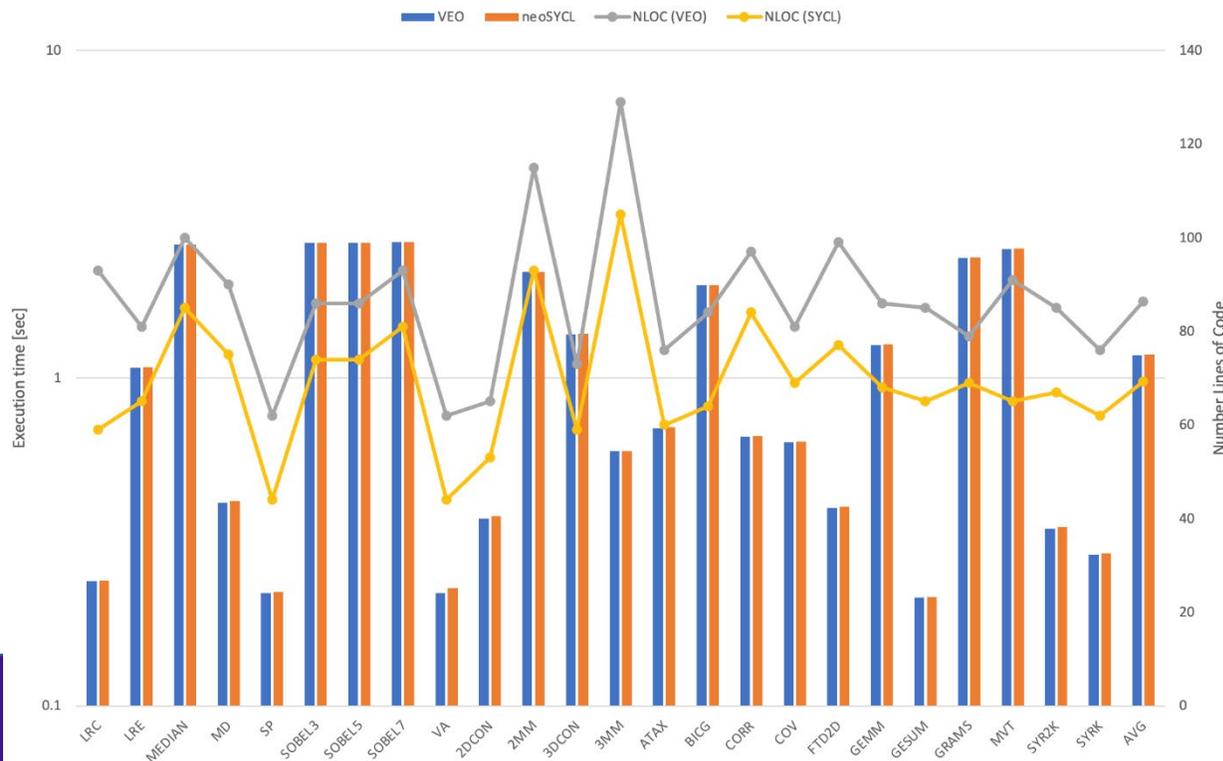
```

VEO-SYCL-Bench's vec\_add

各ベンチマークのカーネル部分だけコピーしてそれ以外はシンプルなコードに書き直し

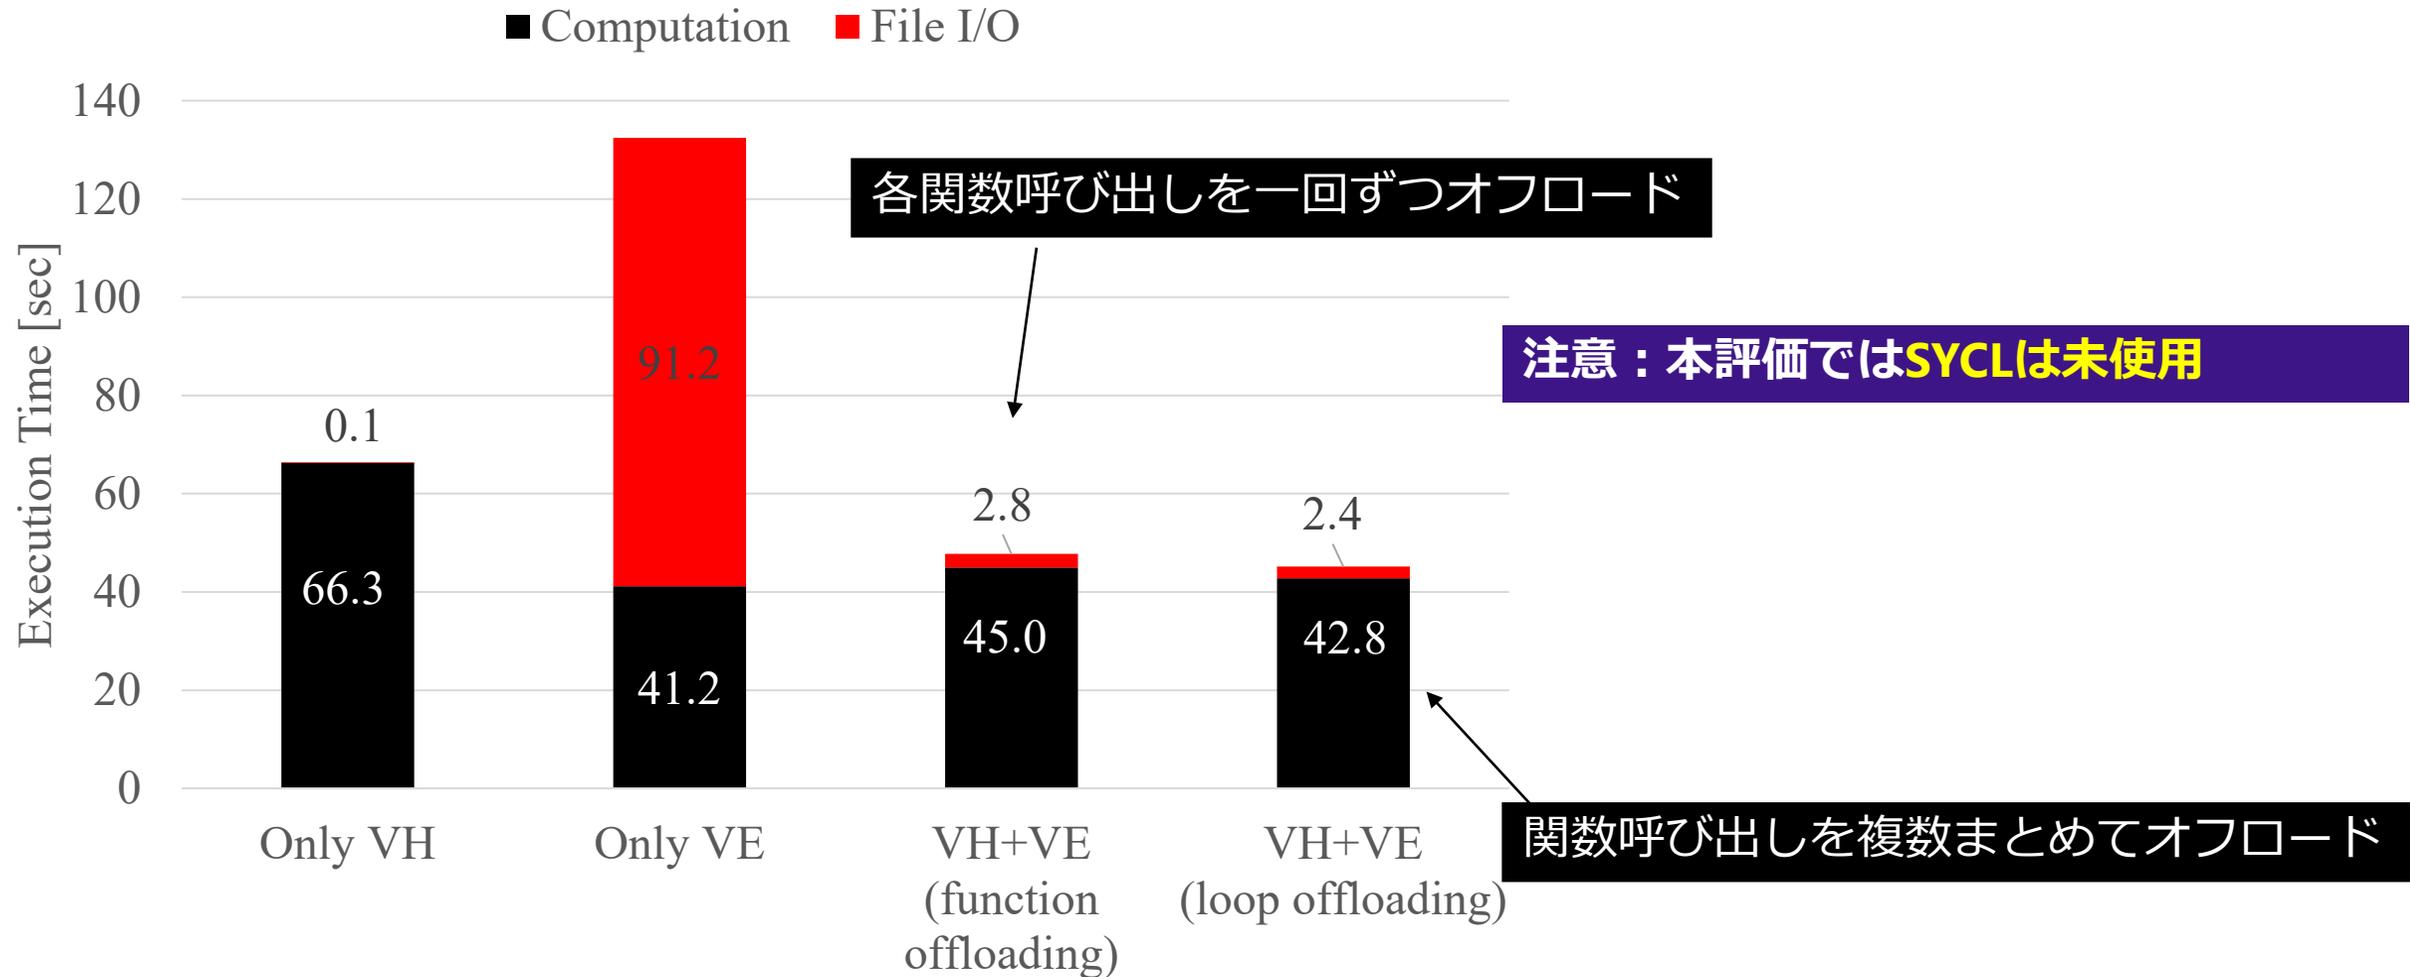
# 生産性と性能の評価

- neoSYCLとVEOとの性能差は平均**わずか 0.42%**
  - 高抽象化に伴う実行時オーバーヘッド (abstraction penalty) は無視できるレベル
- SYCLコードの複雑さはVEOコードよりも**常に低い**
  - SYCLプログラミングにより他プラットフォームとの移植性や生産性を改善



	SYCL	VEO
Avg.NLOC	<b>69.2</b>	86.4
Avg.CCN	<b>10</b>	12
Avg.token	<b>653.0</b>	764.5

# VHとVEを適材適所で利用する効果



# 最近の開発状況

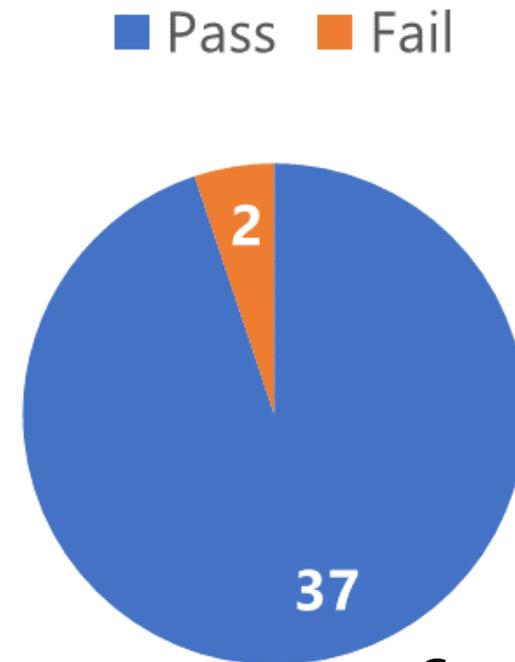
## • 規格適合性テストとコードリファクタリング

- DPC++ test cases (basic tests) <https://github.com/intel/llvm/tree/sycl/sycl/test>

🔍 sycl ▾ [llvm / sycl / test / basic\\_tests /](#) Go to file Add file ▾ ⋮

DenisBakhvalov [SYCL] Fix is\_device\_copyable with range rounding (#4478) 2d28cd4 2 days ago History

..		
accessor	[SYCL] Transition from ONEAPI/INTEL to ext::oneapi/intel namespaces (#...	2 months ago
buffer	[SYCL] Warning if use sycl without dynamic C++ RT on Windows (#2501)	6 months ago
free_function_queries	[SYCL] Move free function queries to experimental namespace (#4090)	2 months ago
handler	[SYCL] Correct CFE behavior with named lambdas in unnamed-lambda mode (...)	2 months ago
marray	[SYCL] Warning if use sycl without dynamic C++ RT on Windows (#2501)	6 months ago
queue	[SYCL] Move tests with dependencies to on-device directory (#2732)	10 months ago
stream	[SYCL] Move tests with dependencies to on-device directory (#2732)	10 months ago
vectors	[SYCL] Deprecate half from global namespace (#4363)	7 days ago
SYCL-2020-spec-const-ids-order.cpp	[SYCL] Switch to using integration footer by default (#3777)	2 months ago
SYCL-2020-spec-constants.cpp	[SYCL] Add missed constexpr for vec (#4324)	last month
address_space_traits.cpp	[SYCL] Sub-group load/store for raw pointers (#3255)	6 months ago
aliases.cpp	[SYCL] Deprecate half from global namespace (#4363)	7 days ago
built-ins.cpp	[SYCL][ROCM] Setup lit tests for ROCm plugin (#4163)	23 days ago
context.cpp	[SYCL] Warning if use sycl without dynamic C++ RT on Windows (#2501)	6 months ago
define_vendors.cpp	[SYCL] Predefine SYCL macros with vendor strings (#4498)	4 days ago
device.cpp	[SYCL] Warning if use sycl without dynamic C++ RT on Windows (#2501)	6 months ago



### 未サポートの機能

- parallel\_for\_work\_group
- parallel\_for\_work\_item
- nd\_item
- ndranger

OpenCL由来の機能をサポートしても性能を期待できないため\*。  
\* Takizawa et al. (PARCO2021)

Coverage: **94.8%**

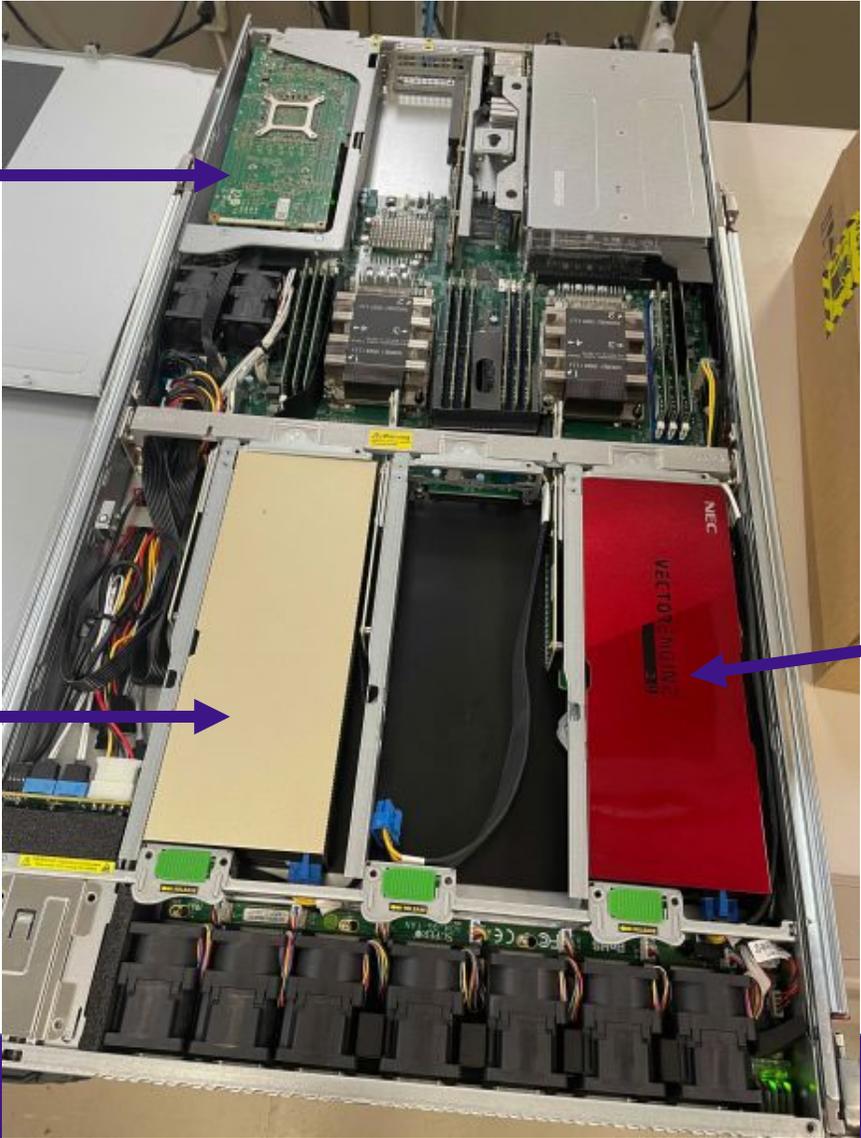
未サポートの機能 (`parallel_for_work_group`と`parallel_for_work_item`)に関する2件以外はテスト合格

# さらに多様なアクセラレータ

FPGA



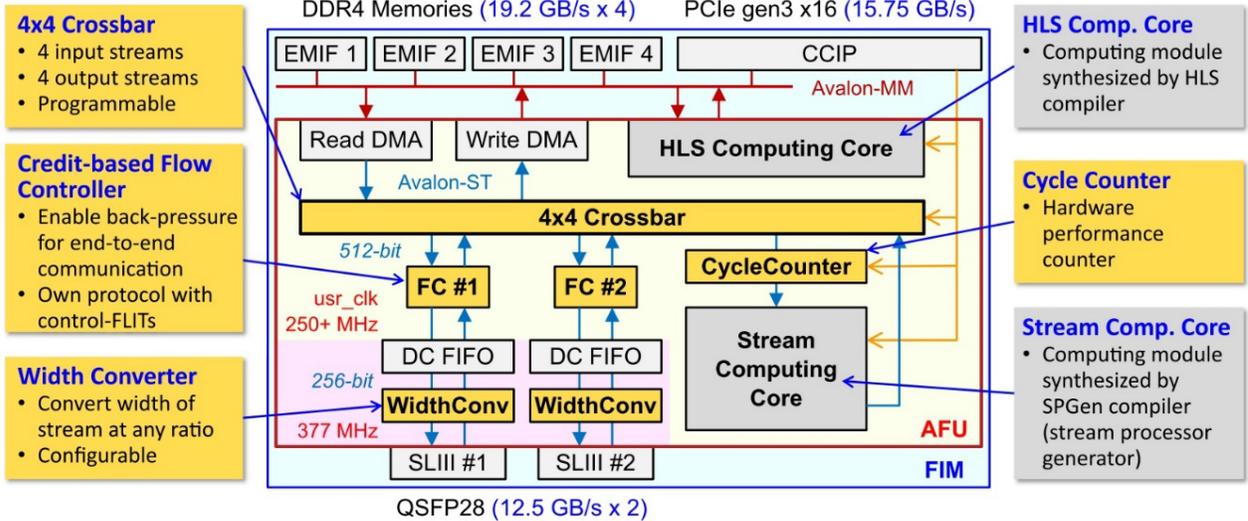
GPU



VE

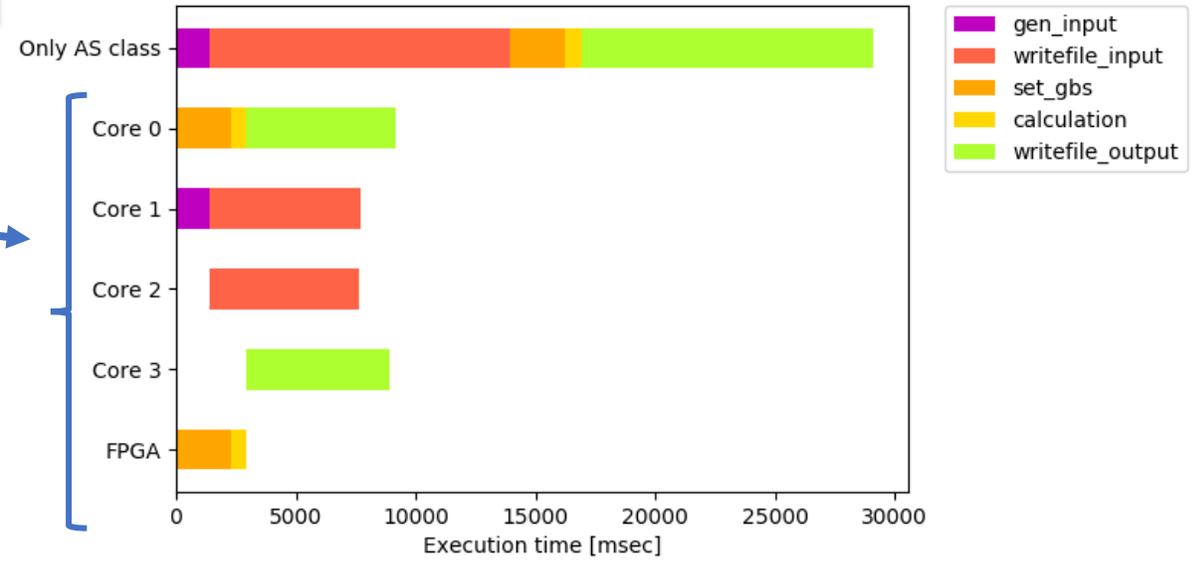
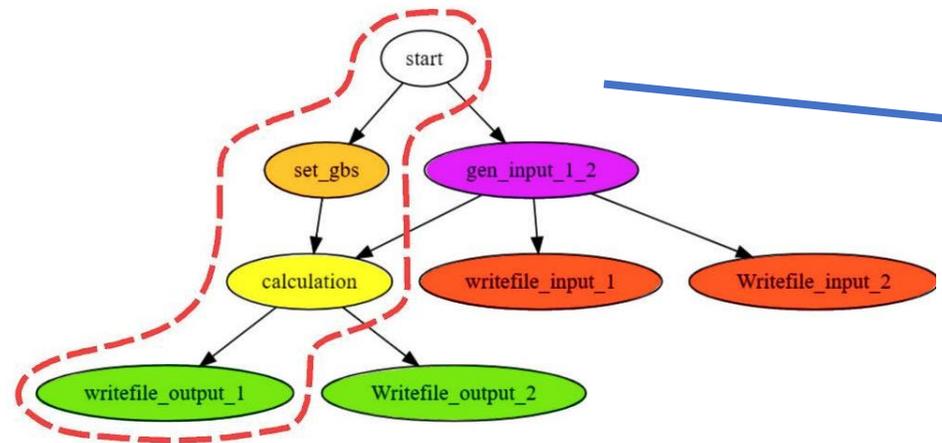


# SYCL for FPGA



**The ESSPER project**  
 FPGAクラスタを利用するためのフレームワーク  
 led by 佐野健太郎 博士 (RIKEN R-CCS)

## SYCL for Collaboration between CPU and FPGA



# まとめ

- Vector Engine (VE)は**ベクトル向きの処理で効果を発揮**
  - メモリ律速になりがちな科学技術計算での活躍を期待
  - x86とVEはそれぞれ異なる性能特性 → 適材適所の分担が重要
- neoSYCL : SX-ATでの**SYCLによるオフロードプログラミング**
  - カーネル部分を切り出してVEO経由でカーネル呼出しする簡易SYCL実装
    - 実行時のややこしい処理はVEOが担当 ☺
  - 性能と生産性の両面で有望
  - 現在も精力的に開発中！ 近日公開予定 (未定)
- **今後の展開**
  - 他のアクセラレータへのオフロードに利用 (ESSPER)
  - カーネル切り出し時で適切にコード変換することでさらなる性能向上の可能性