Графический API Apple-устройств - теперь и на C++

История/особенности/микро введение в Metal

Платон Фомичев, ООО Элверилз 2024 /stauff@elverils.com /

План доклада

Немного 👨🏻‍💻 магии

- История трехмерной графики на Apple устройствах
- Зачем нужен Metal. Есть ли смысл его использовать?
- Как программировать на metal. Можно ли сразу использовать C++?
- Metal-cpp - что за библиотека и зачем она нужна
- MSL - язык шейдеров - это обычный C++? Переход от HLSL к MSL

О чем мы не поговорим

А жаль

- О том как программировать трехмерную графику
- О практическом применении Metal

Стародавние времена

Сначала впереди, а в конце позади

- Одна из первых по настоящему стабильных OpenGL имплементаций
- Зависимость и постоянные разборки с NVIDIA/AMD
- Они же писали драйвера
- LLVM родился для OpenGL
- OpenGL 4.1+ и на этом все
- Никакого инструментария/никакой отладки
- Заморожен и переписан с использованием Metal для ARM64

Современные реалии

Становится веселее

- Metal был первым на празднике жизни нового поколения GPU API
- Metal изначально заточен на свои собственные GPU
- Metal используется во всех устройствах Apple
- API для разных устройств имеет минимальные отличия
- iOS/iPad OS/macOS/tvOS могут использовать одно и то же API
- Хороший инструментарий

Знакомство с Metal

И даже на Intel архитектуре

- Apple M1/M2/M3 CPU
- Дискретные устройства AMD в лэптопах
- Интегрированная графика Intel
- Полноценные AMD видеокарты в MacPro
- Любое другое устройство - даже Apple Watch
- Симулятор на Mx CPU

Знакомство с Metal

Но лучше на ARM64

- Не такие простые видеочипы M1/M2/…
- TBDR архитектура
- Общая память, и ее может быть очень много
- RTX
- Специфические фишки платформы (tile shaders, programmable blending)
- BCx компрессия из коробки
- И много много другого…

Зачем нужен Metal

Есть же прекрасные кроссплатформенные технологии …

- Удобно/быстро/поддержка разнообразных утилит
- Графика это 5% кода, а драма обычно на все 50%
- Использование ресурсов GPU для вычислений
- Поддержка всего спектра устройств Apple
- Отладка шейдеров
- Валидация команд

В чем суть Metal

Параллельная вселенная

- CPU/GPU должны работать параллельно, каждый в своей вселенной, предпочтительно без синхронизации
- API простое и по умолчанию все делает за разработчика
- При желании Metal может перейти в полностью ручной режим
- Metal полностью многопоточная система, разработчик может загружать GPU параллельно из нескольких потоков
- API ориентированно на будущее - с прицелом на GPU Driven Pipelines

Как программировать Metal

На сцену выходит Objective-C

- Основной язык Apple API - Objective C - бодрый старик с богатой историей
- Swift вне нашего интереса
- Полностью интегрирован в современные CLANG компиляторы C++
- Objective C++ (.m и .mm файлы)
- Идет с ОС фреймворками Cocoa и имеет два режима управления памятью
- Написать программу для Metal полностью на C++ без Obj-C было невозможно

Как программировать Metal

А так ли все грустно?

- При классическом разделении графического API на отдельную подсистему задача решается тривиально
- C++ классы могут вызывать методы ObjC без каких либо ограничений
- Синтаксический ‘суп’ как наиболее неприятное последствие
- C++ классы могут хранить указатели на ObjC классы
- ```
  // Draw
  void xx::metal::MetalRenderer::DrawArrays(const int firstVertex, const int nVertices)
  {
      PreDraw();

      [m_RenderCommandEncoder drawPrimitives: xx2MTL::PrimitiveType(m_CurrentState.m_PrimitiveTopology) vertexStart:firstVertex vertexCount:nVertices];

      PostDraw();
  }
  ```
  ```

Как программировать Metal

А так ли все грустно?

- А что такое m_RenderCommandEncoder?

```
OBJC_ID(MTLRenderCommandEncoder)    m_RenderCommandEncoder;
```

```
#ifdef __OBJC__
#   include    <Metal/Metal.h>
#   define     OBJC_I(type)     type*
#   define     OBJC_ID(type)    id<type>
#else
#   define     OBJC_I(type)     void*
#   define     OBJC_ID(type)    void*
#endif
```

- Единственное тонкое место - управление памятью

Как программировать Metal
А так ли все грустно?

- Переключение типа файла в Xcode на Objective C++

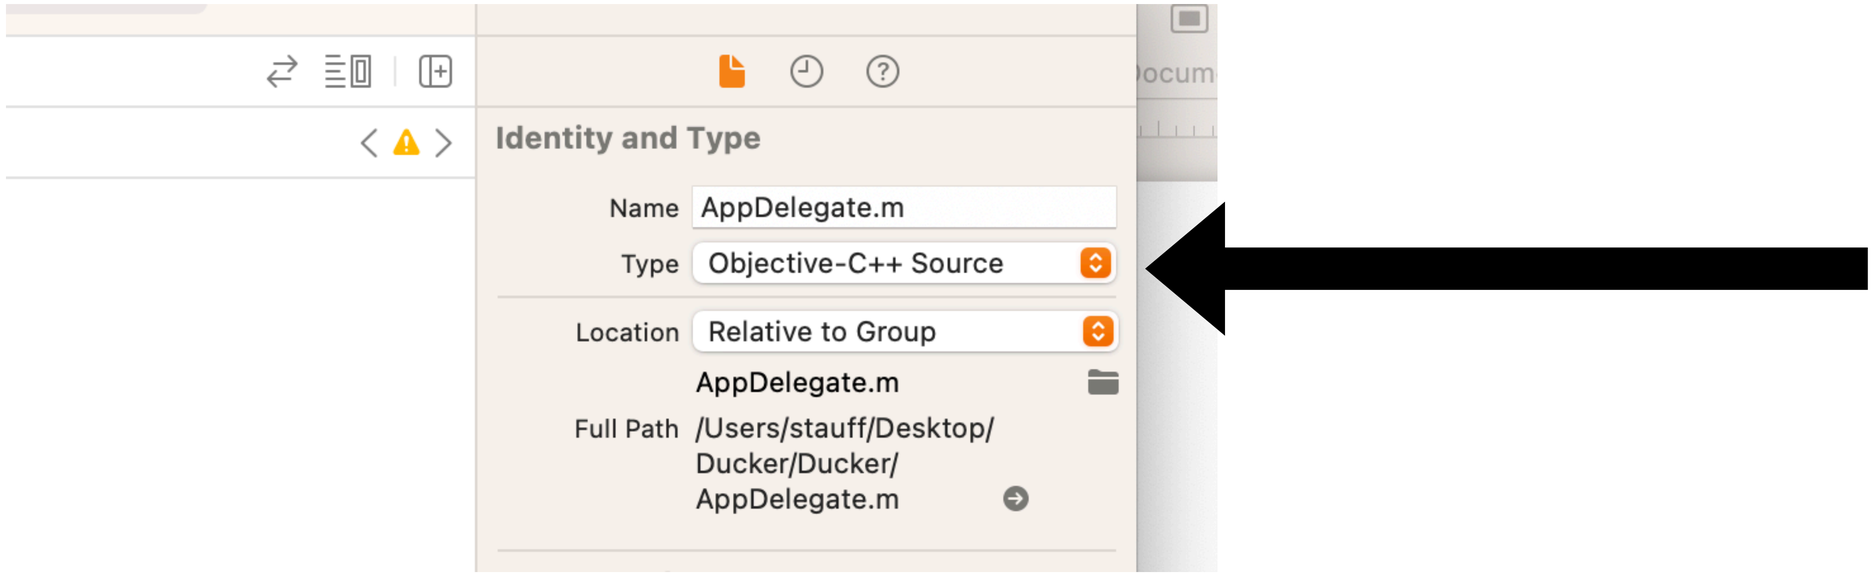

Как программировать Metal

На сцену выходит metal-cpp

- https://developer.apple.com/metal/cpp/
- Враппер над ObjC вызовами/вызовы сделаны на самом низком уровне - почти нулевая потеря производительности
- Полная имплементация всех API, без каких либо расхождений для всех устройств
- Возможность компоновки всего в единственных header файл

```
#define NS_PRIVATE_IMPLEMENTATION
#define CA_PRIVATE_IMPLEMENTATION
#define MTL_PRIVATE_IMPLEMENTATION
#include <Foundation/Foundation.hpp>
#include <Metal/Metal.hpp>
#include <QuartzCore/QuartzCore.hpp>
```

Сравним вызовы

C++ vs ObjC++

```
MTL::CommandBuffer* pCmd = _pCommandQueue->commandBuffer();
MTL::RenderCommandEncoder* pEnc = pCmd->renderCommandEncoder( pRpd );

pEnc->setRenderPipelineState( _pPSO );
pEnc->drawPrimitives( MTL::PrimitiveTypeTriangle,
                      NS::UInteger(0),
                      NS::UInteger(3));

pEnc->endEncoding();
pCmd->presentDrawable( pView->currentDrawable() );
pCmd->commit();
```

metal-cpp

Objective-C

```
id<MTLCommandBuffer> cmd = [_commandQueue commandBuffer];
id<MTLRenderCommandEncoder> enc = [cmd renderCommandEncoderWithDescriptor:pRpd];

[enc setRenderPipelineState:_pPSO];
[enc drawPrimitives:MTLPrimitiveTypeTriangle
        vertexStart:0
        vertexCount:3];

[enc endEncoding];
[cmd presentDrawable:view.currentDrawable];
[cmd commit];
```

Как программировать Metal

Что там с памятью моей стало?

- Два режима управления - ручной и автоматический
- Все объекты Metal наследники базового класса в котором реализован подсчёт ссылок
- Для проектов полностью на C++ имеет смысл глобально переключить режим управления памятью в ручной режим
- Почти все объекты Metal удаляются отложено поэтому нужно помнить про возможность разрастания пула памяти без использования autorelease
- Обязательно читаем полезную и нужную документацию

Простой подсчет ссылок

Пронизывает все классы macOS

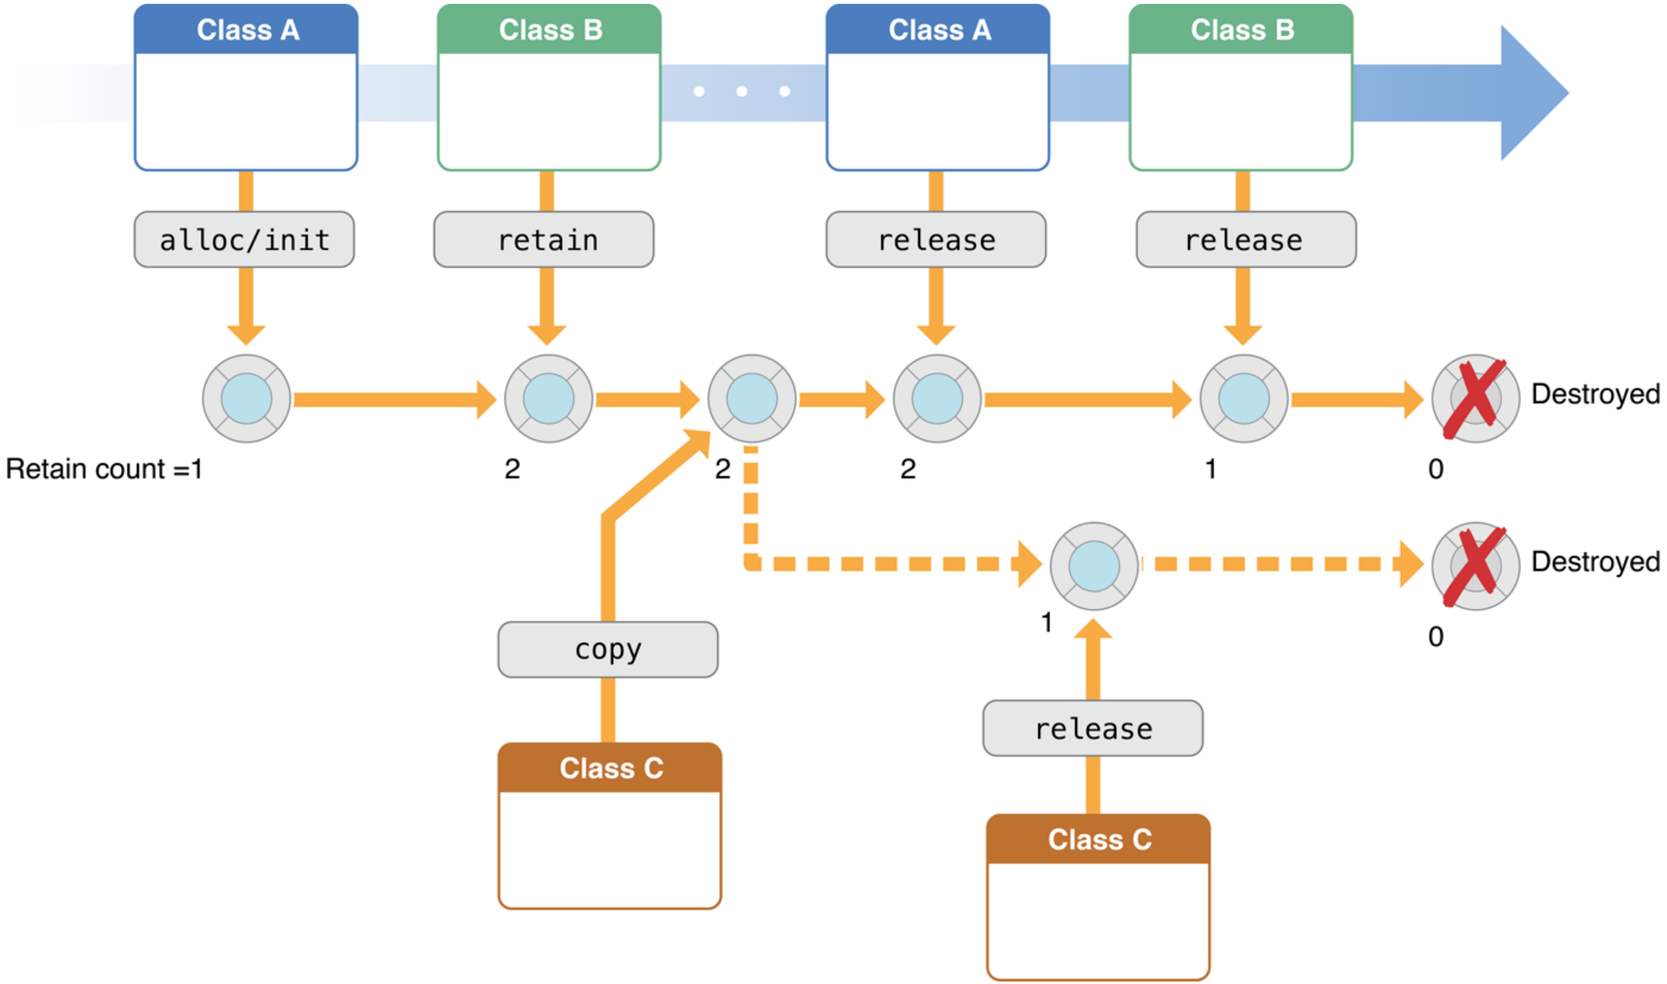

Отложенные пулы

90% объектов Metal отложенные

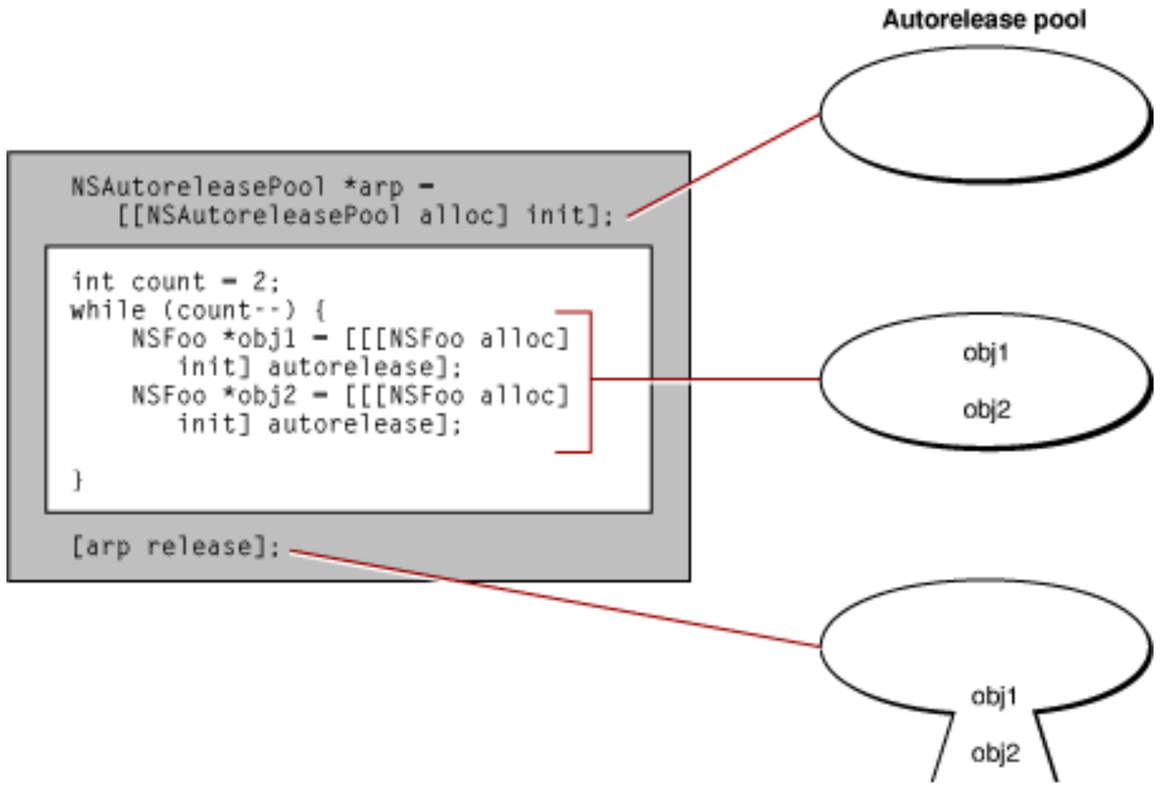

Инструментарий

Зомби!

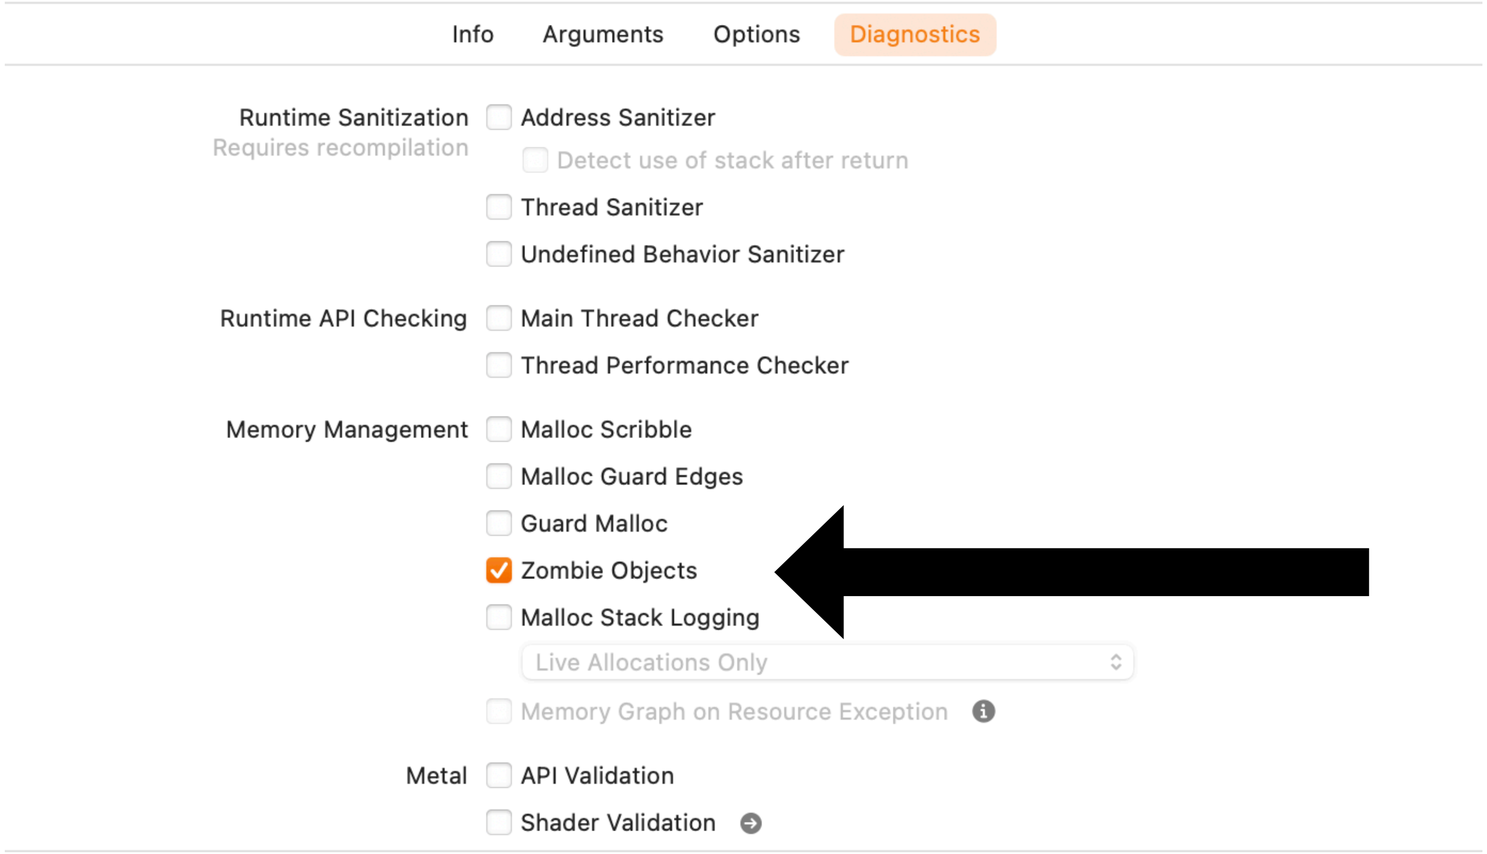

Инструментарий

Контроль ссылок

Полная информация о всех +1 / -1 операциях

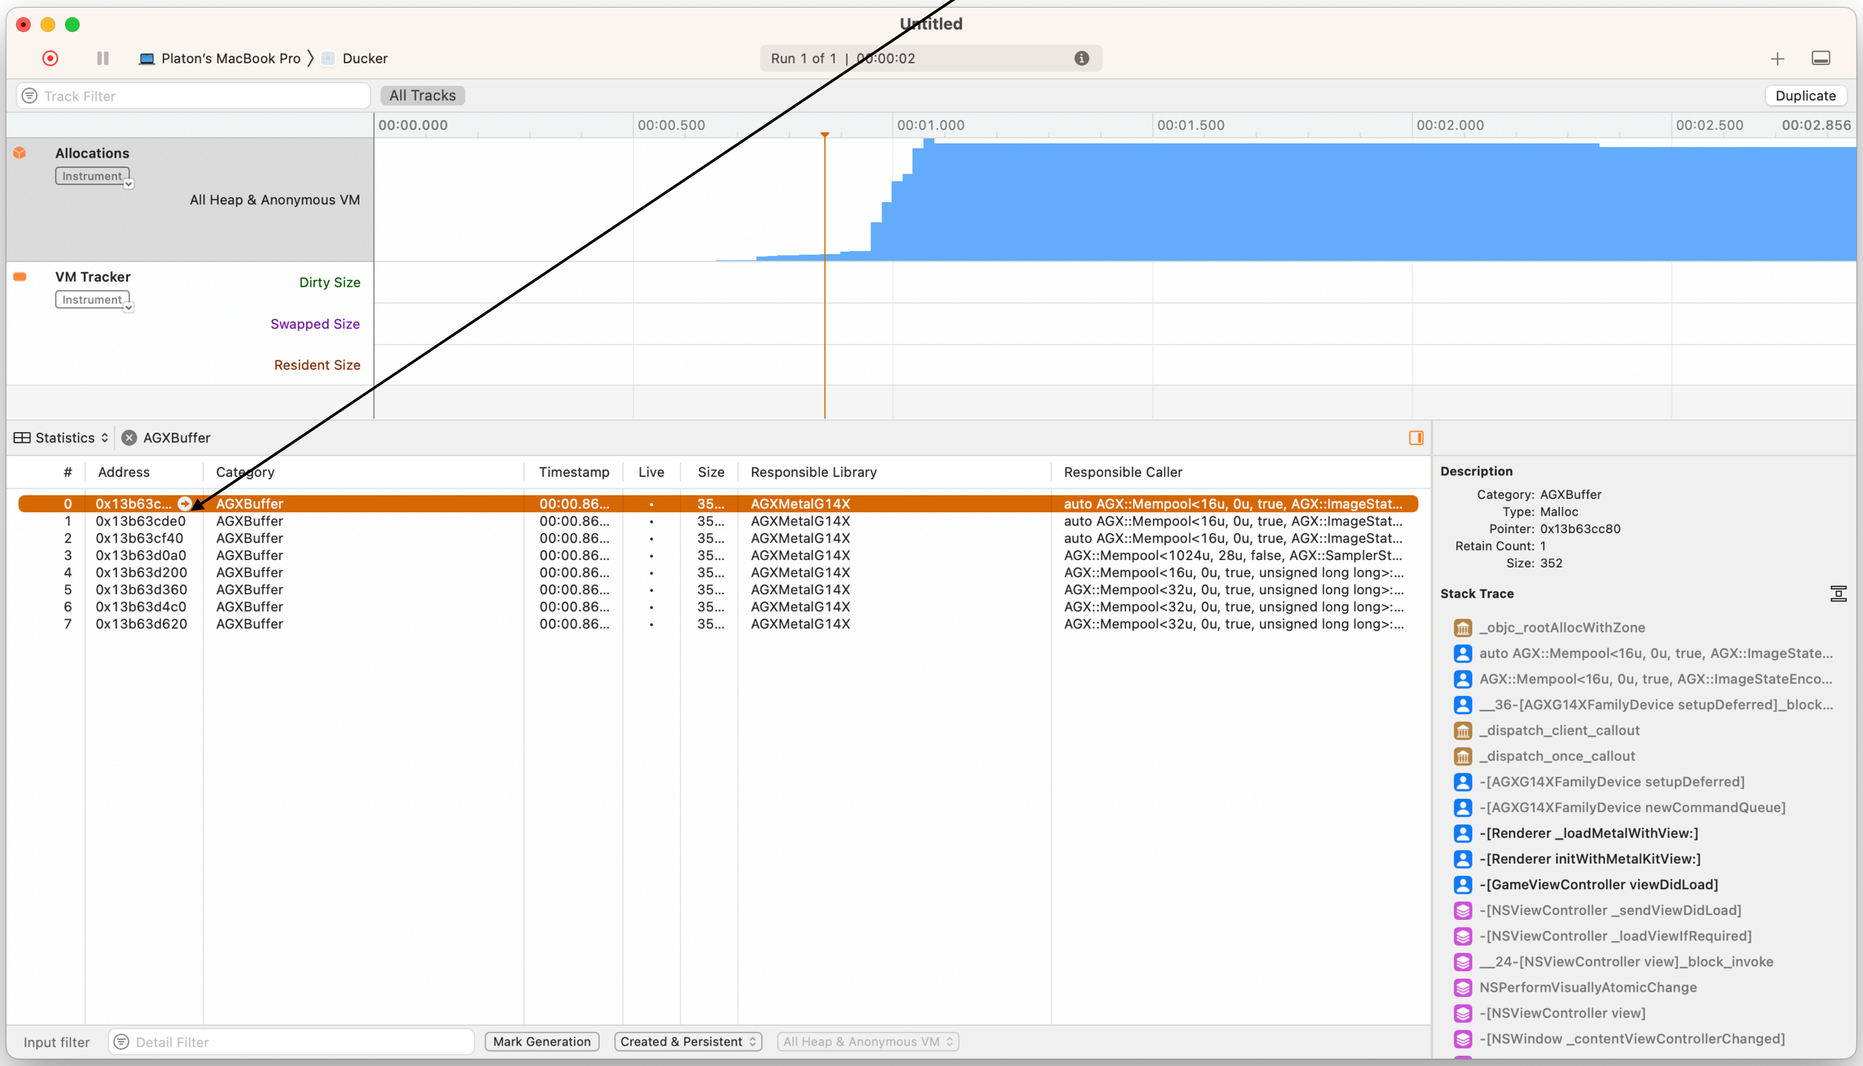

Инструментарий
Instruments

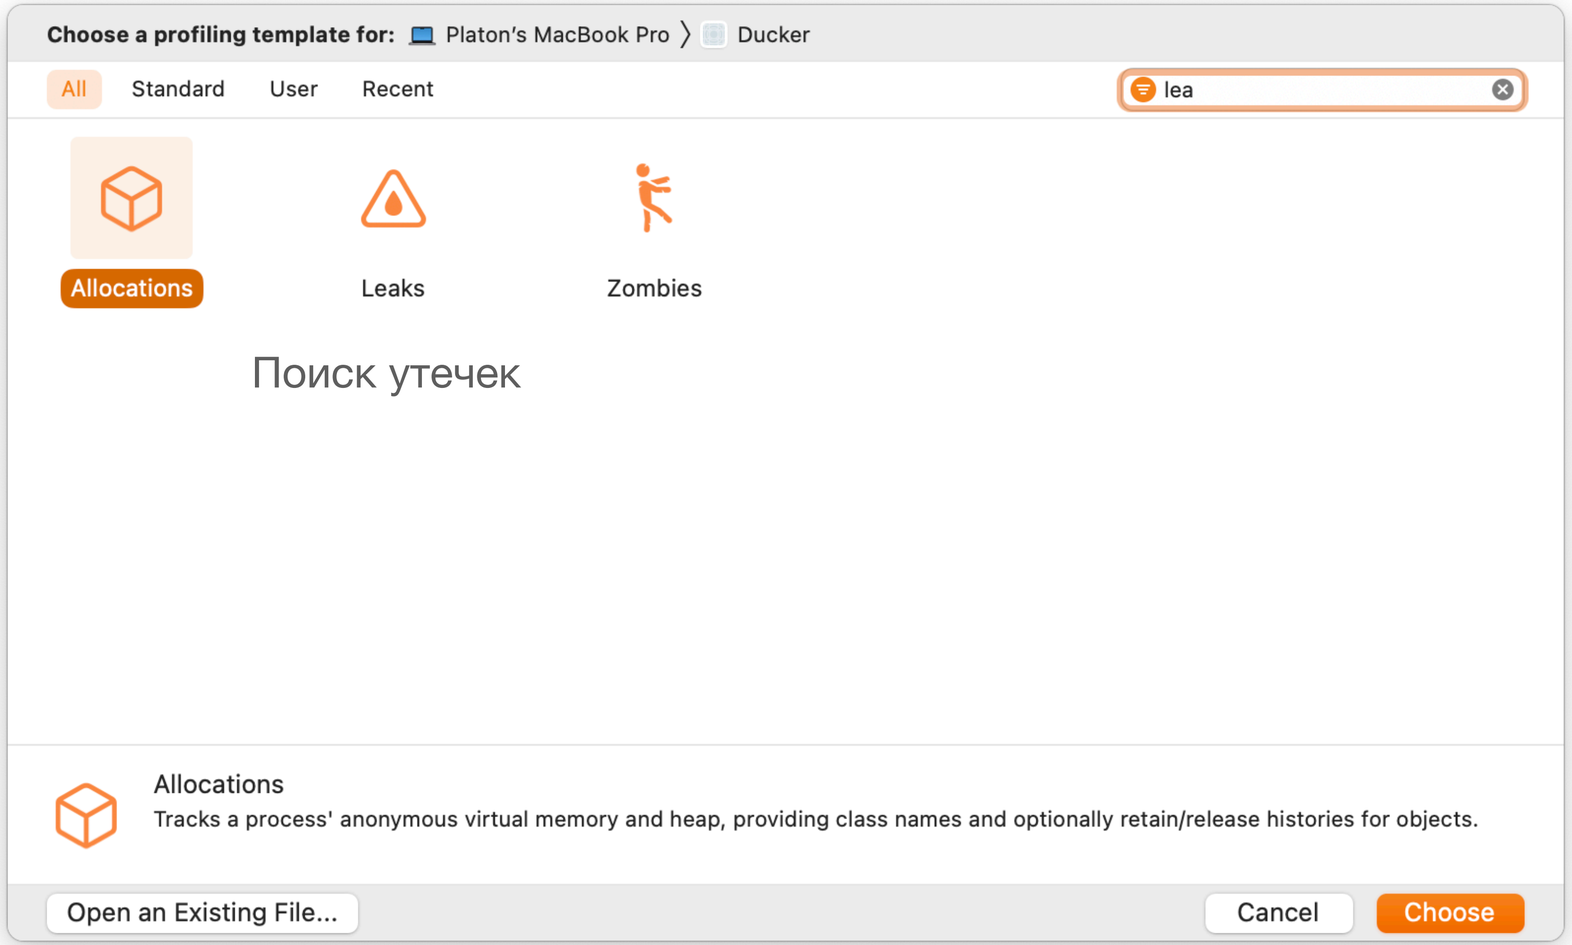

Полный граф памяти

С потенциальным нахождением утечек и визуализатором

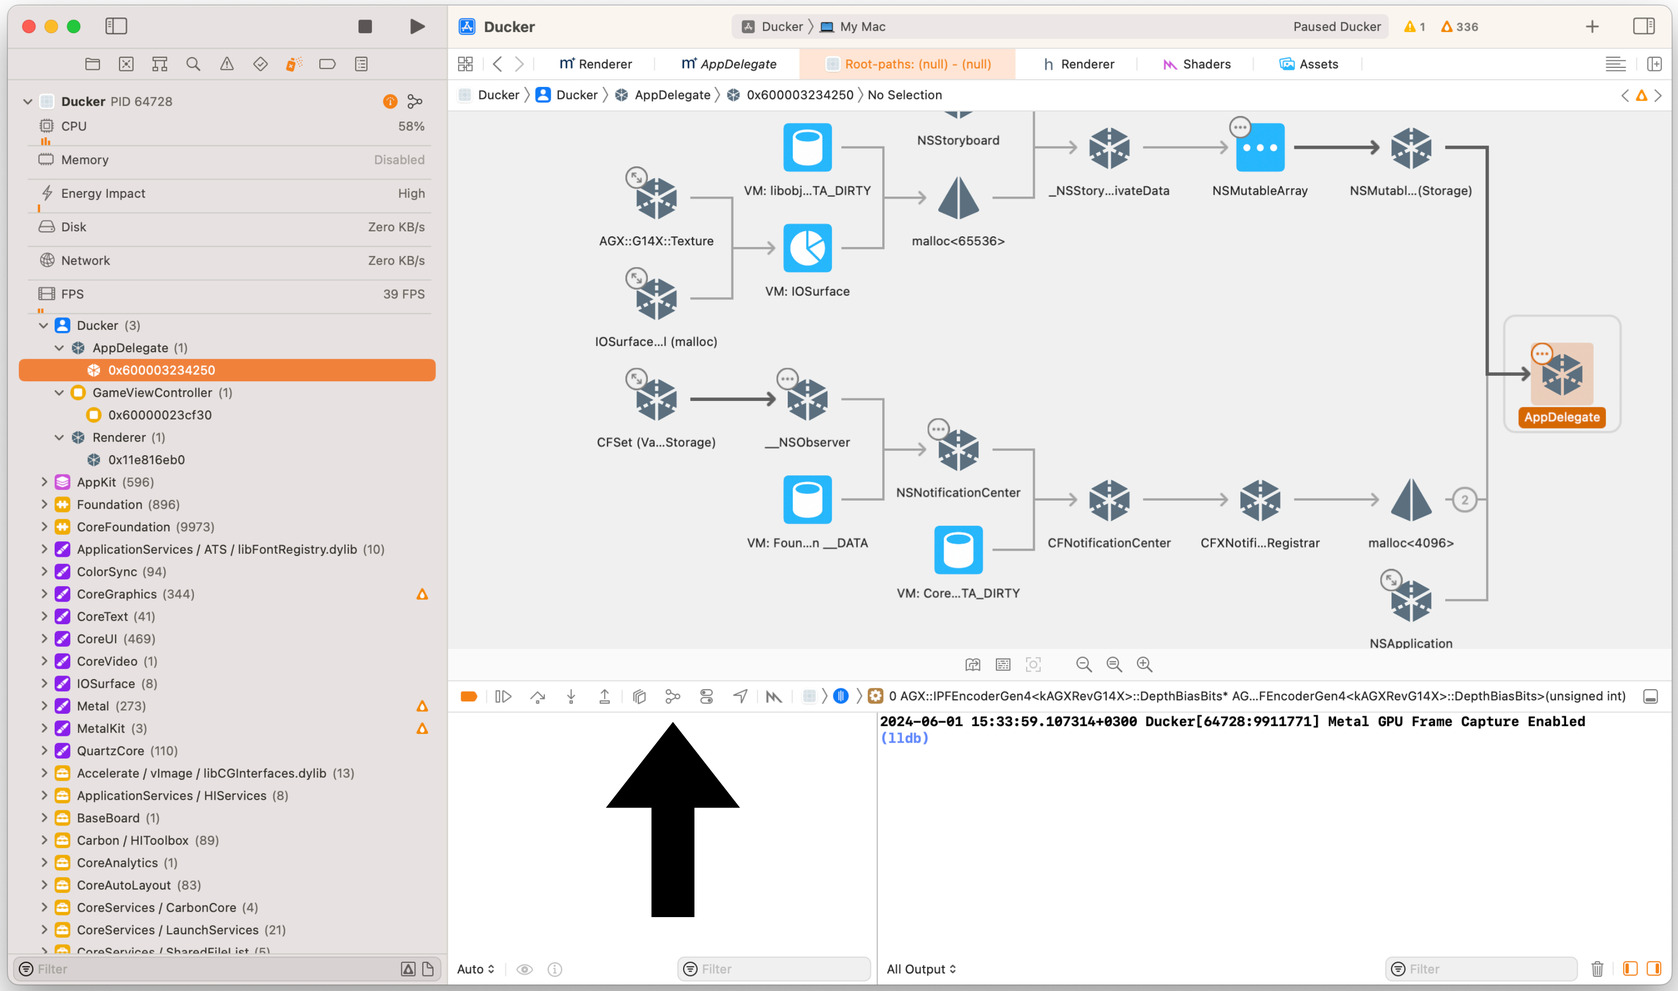

Как программировать Metal

Что там с памятью моей стало?

- Cocoa memory management обязателен для чтения и понимания
- К счастью инструменты анализа памяти на высоте
- Zombie анализ эффективно найдёт проблемы
- Другие инструменты могут визуализировать полный жизненный путь любого объекта
- Для графики нормально иметь сотни временных объектов, но ненормально постоянно аллоцировать память во время построения кадра

Как программировать Metal

Требуются примеры

- Самый простой пример встроен в Xcode (Game project)
- Достаточно много примеров имеют C++ вариант
- https://developer.apple.com/metal/sample-code/
- 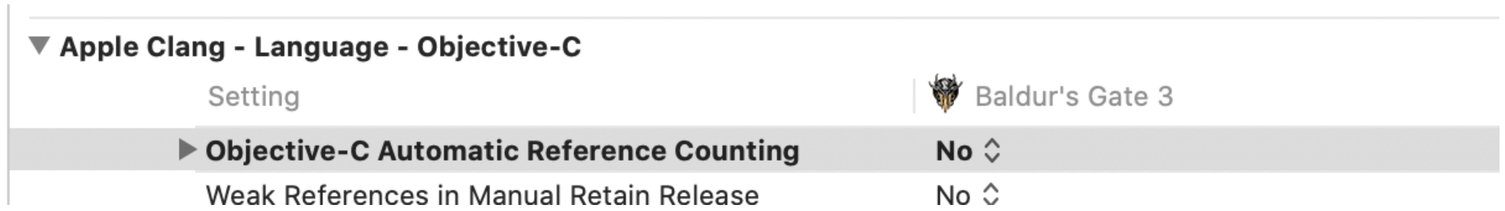

- Наиболее простой метод учиться трехмерной графике - это включить валидатор и отлавливать кадры

А как же шейдеры?

Они всегда были на C++

- Язык шейдеров Metal - MSL это C++
- Ограничений много, но они разумные - нет lamda, exceptions, rtti
- Нет new/delete и vtbl
- Нет goto
- Нет std
- Своя библиотека
- Стандартный препроцессор

HLSL vs MSL

Выглядит грустно

- Потому что нет глобальных переменных
- Потому что матрицы перевернуты
- Потому что мы формируем библиотеку при помощи компоновщика
- Потому что часть исходного кода уже утеряна
- Потому что люди ленивы

HLSL vs MSL

Кто что напридумывал

- GamePortingToolkit от Apple
- ShaderConductor от Microsoft
- SpirV-Cross
- Тысячи их
- SLANG (наш личный проект, доработанный напильником)
- Руки.sys никто не отменял

Типичный HLSL

BC4 Compress

```
uint2 CompressAlphaBlock(in const float2 iTc)
{
    int texels[16];
    ExtractAlphaBlock(texels, iTc);

    uint endpoints6[2] = {0, 0};
    uint endpoints8[2] = {0, 0};

    float error6 = 0.0f;
    float error8 = 0.0f;
    bool flat = false;

    Compute6(endpoints6, error6, flat, texels);

    if (!flat)
        Compute8(endpoints8, error8, texels);
    else
        error8 = 1000000.0f;

    uint i[16];
    uint selected_endpoints[2];
    [branch]
    if (error8 <= error6)
    {
        selected_endpoints[0] = endpoints8[0];
        selected_endpoints[1] = endpoints8[1];
    }
    else
    {
        selected_endpoints[0] = endpoints6[0];
        selected_endpoints[1] = endpoints6[1];
    }

    Encode(i, selected_endpoints, flat, texels);

   return block;
}
```

```
PsOut main(in const PsIn psIn)
{
    PsOut psOut;
    psOut.block = CompressAlphaBlock(psIn.texCoord);
    return psOut;
}
```

Типичный MSL

BC4 Compress

```
static uint2 CompressAlphaBlock(float2 iTc, sampler PointClampSampler, texturecube<float>
source, constant const _CompressParams& CompressParams)
{
    int texels[16];
    ExtractAlphaBlock( texels, iTc, PointClampSampler, source, CompressParams );

    uint endpoints6[2];
    uint endpoints8[2];

    float error6 = 0.0f;
    float error8 = 0.0f;
    bool flat = false;

    Compute6( endpoints6, error6, flat, texels );

    if (!flat)
        Compute8( endpoints8, error8, texels );
    else
        error8 = 1000000.0f;

    uint i[16];
    uint selected_endpoints[2];
    //[branch]
    if (error8 <= error6)
    {
        selected_endpoints[0] = endpoints8[0];
        selected_endpoints[1] = endpoints8[1];
    }
    else
    {
        selected_endpoints[0] = endpoints6[0];
        selected_endpoints[1] = endpoints6[1];
    }

    Encode(i, selected_endpoints, flat, texels);

   return block;
}
```

```
fragment uint2 CompressBC4_PS(PsIn input [[stage_in]], sampler
PointClampSampler, texturecube<float> source, constant const _CompressParams&
CompressParams)
{
    uint2 Out;
    Out = CompressAlphaBlock(input.texCoord, PointClampSampler, source,
CompressParams);

    return Out;
}
```

HLSL vs MSL

Практические советы

- Основная головная боль - это глобальные переменные, все остальное ерунда
- Решений несколько:
  - Передавать глобальные переменные как аргументы функций
  - Создать структуру обертку и передавать только ее
  - Создать класс обертку и работать в его рамках

HLSL vs MSL

Практические советы

- MSL пытается жестко оптимизировать, но если ему не помогать..
- Передаем все по ссылке, в HLSL вообще такого понятия нет там все всегда по ссылке
- Не увлекаемся вложенными структурами (особенно пустыми)
- Помним о том что большинство типов (float3) выровнены и поинтерная математика на них приведет к неверным результатам (packed_float3)
- Активно используем air-objdump с ключом -disassemble-all чтобы посмотреть на получившуюся IR
- Наличие memcpy() - верный признак что все пошло не так

HLSL vs MSL

Практические советы

- Минимизируем über шейдера
- Не пытаемся делать inline за компилятор или разворачивать циклы
- static const превращается в constant const
- Можно пользоваться шаблонами особенно это важно при поддержке half/float вариантов
- Собираем все через консоль - так оно проще и нагляднее
- xcrun metal, metallib, metal-ar

Немного терминальной магии

Глаза забыли, а руки еще помнят VI

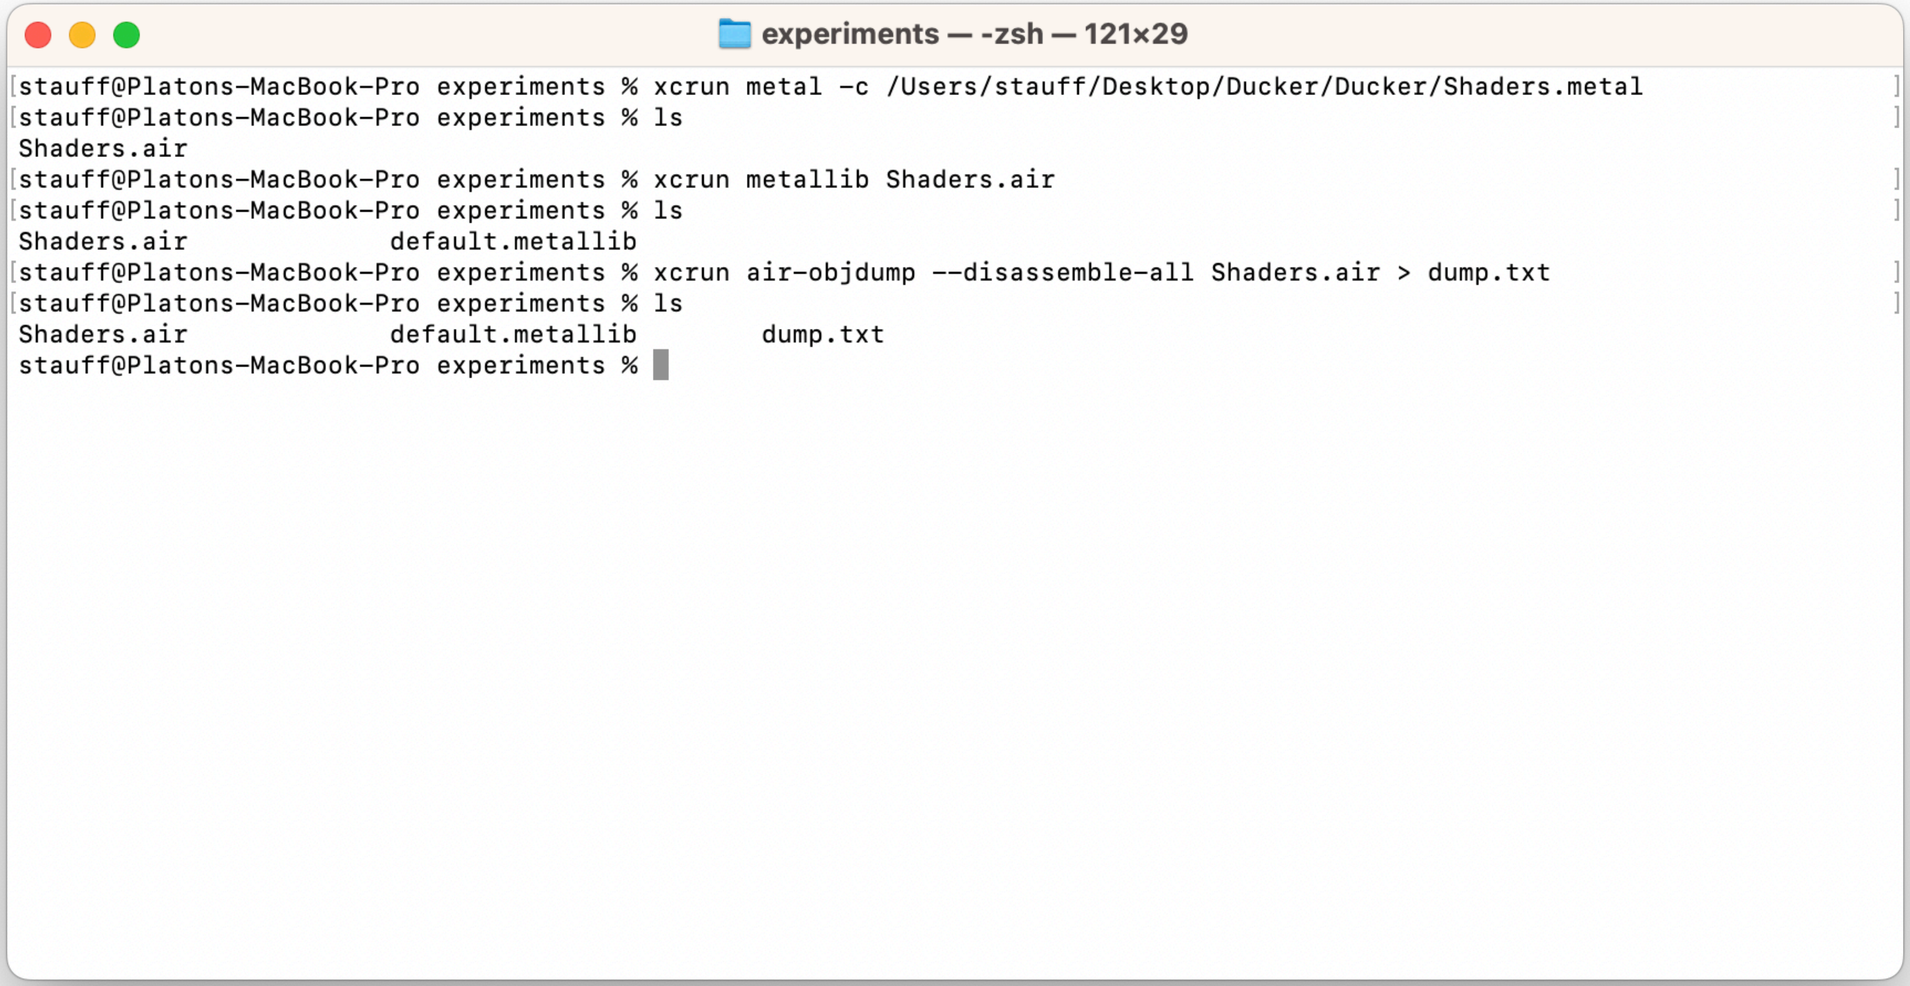

Так выглядит IR LLVM/Metal

При желании легко читается

```
!0 = !{i32 2, !"SDK Version", [2 x i32] [i32 13, i32 3]}
!1 = !{i32 1, !"wchar_size", i32 4}
!2 = !{i32 7, !"air.max_device_buffers", i32 31}
!3 = !{i32 7, !"air.max_constant_buffers", i32 31}
!4 = !{i32 7, !"air.max_threadgroup_buffers", i32 31}
!5 = !{i32 7, !"air.max_textures", i32 128}
!6 = !{i32 7, !"air.max_read_write_textures", i32 8}
!7 = !{i32 7, !"air.max_samplers", i32 16}
!8 = !{<{ <4 x float>, <2 x float> }> (<3 x float>, <2 x float>, %struct.Uniforms addrspace(2)*)* @vertexShader, !9, !12}
!9 = !{!10, !11}
!10 = !{!"air.position", !"air.arg_type_name", !"float4", !"air.arg_name", !"position"}
!11 = !{!"air.vertex_output", !"generated(8texCoordDv2_f)", !"air.arg_type_name", !"float2", !"air.arg_name", !"texCoord"}
!12 = !{!13, !14, !15}
!13 = !{i32 0, !"air.vertex_input", !"air.location_index", i32 0, i32 1, !"air.arg_type_name", !"float3", !"air.arg_name", !"position"}
!14 = !{i32 1, !"air.vertex_input", !"air.location_index", i32 1, i32 1, !"air.arg_type_name", !"float2", !"air.arg_name", !"texCoord"}
!15 = !{i32 2, !"air.buffer", !"air.buffer_size", i32 128, !"air.location_index", i32 2, i32 1, !"air.read", !"air.address_space", i32 2, !"air.struct_type_info", !
16, !"air.arg_type_size", i32 128, !"air.arg_type_align_size", i32 16, !"air.arg_type_name", !"Uniforms", !"air.arg_name", !"uniforms"}
!16 = !{i32 0, i32 64, i32 0, !"float4x4", !"projectionMatrix", i32 64, i32 64, i32 0, !"float4x4", !"modelViewMatrix"}
!17 = !{<{ <4 x float>, <2 x float>, <3 x float>, <4 x float>, <3 x float> }> (i32, %struct.DuckSrt addrspace(2)*)* @duckShaderVS, !18, !24}
!18 = !{!19, !20, !21, !22, !23}
!19 = !{!"air.position", !"air.arg_type_name", !"float4", !"air.arg_name", !"Position"}
!20 = !{!"air.vertex_output", !"generated(9TextureUVDv2_f)", !"air.arg_type_name", !"float2", !"air.arg_name", !"TextureUV"}
!21 = !{!"air.vertex_output", !"generated(5vNormDv3_f)", !"air.arg_type_name", !"float3", !"air.arg_name", !"vNorm"}
!22 = !{!"air.vertex_output", !"generated(5vTangDv4_f)", !"air.arg_type_name", !"float4", !"air.arg_name", !"vTang"}
!23 = !{!"air.vertex_output", !"generated(10vPosInViewDv3_f)", !"air.arg_type_name", !"float3", !"air.arg_name", !"vPosInView"}
!24 = !{!25, !26}
!25 = !{i32 0, !"air.vertex_id", !"air.arg_type_name", !"uint", !"air.arg_name", !"vtx_id"}
!26 = !{i32 1, !"air.indirect_buffer", !"air.buffer_size", i32 192, !"air.location_index", i32 0, i32 1, !"air.read", !"air.address_space", i32 2, !"air.struct_type_info
!"air.arg_type_size", i32 192, !"air.arg_type_align_size", i32 16, !"air.arg_type_name", !"DuckSrt", !"air.arg_name", !"srt"}
!27 = !{i32 0, i32 8, i32 0, !"DuckSrtBuffer", !"buffer", !"air.indirect_argument", !28, i32 8, i32 8, i32 0, !"texture2d<float,
sample>", !"colorMap", !"air.indirect_argument", !34, i32 16, i32 8, i32 0, !"texture2d<float, sample>", !"bumpGlossMap", !"air.indirect_argument", !
35, !"air.struct_type_info", !36, i32 32, i32 160, i32 0, !"DuckSrtConstant", !"constData", !"air.indirect_argument", i32 3}
```

Подытожим

Что нового мы узнали сегодня

- Objective-C легко превращается в Objective-C++ и при правильном формировании проекта нам не нужно никаких дополнительных библиотек
- При категорическом его неприятии есть metal-cpp
- В любом случае нужно знать как управлять памятью в Cocoa программе
- Программировать metal просто - не надо мучаться с кросс решениями - надо просто попробовать
- Перевод HLSL->MSL неприятная задача и лучше ее решать приятными подходами, чтобы не было мучительно больно потом

Подытожим

Что нового мы узнали сегодня

- На сайте Apple полно примеров и хорошая документация
- Mx устройства предпочтительная платформа для разработки
- Инструментарий более чем адекватный
- Большинство технологий и подходов работают на всех устройствах
- Apple GamePortingToolkit интересен для опытных разработчиков на DX12

Вопросы