


СЕМЕЙСТВО УСТРОЙСТВ НА БАЗЕ СБИС 1879ВМ8Я

ЧАСТО ЗАДАВАЕМЫЕ ВОПРОСЫ



Оглавление:

Общие вопросы	3
Вопросы по ПО, драйверам и структуре архитектуры	6
Вопросы по инициализации, загрузке и диагностике	12
Краткое описание последовательности установки ПО поддержки	20
Вопросы по производительности NMC4 для БПФ	28
Приложение 1 Производительность для ядра NMC4 с плавающей точкой	30
Вопросы по объединению и распараллеливанию	32

Данное руководство применимо для следующих модулей:



NM CARD



NM CARD MINI



NM MEZZO MINI



MC127.05



NM MEZZO PCIe/104



NM Vision



NM Pilot

Общие вопросы

Вопрос:

Как происходит обработка информации на процессоре ?

Ответ:

Предполагается, что имеется основной процессор и целевая ОС, а также наш сопроцессор K1879BM8Я.

На стороне сопроцессора имеется библиотека загрузки и обмена (БЗиО) для того, чтобы загружать какие-либо программы на основной процессор и запускать их там.

БЗиО работает с драйвером, но интерфейсом с пользовательской программой является БЗиО.

NMDL также «общается» через БЗиО. Однако, является более высокоуровневым интерфейсом именно для работы с инференсом нейронных сетей.

В итоге: информация обрабатывается либо через компилятор NMDL, либо через БЗиО, либо же через интерфейсы наших библиотек.

Вопрос:

Какое общее назначение модуля NM Mezzo 104/PCIe ?

Ответ:

NM Mezzo 104/PCIe является модулем расширения(сoproцессором) для основного устройства, на котором уже может быть установлена ОС Linux, со всеми стандартно встроенными библиотеками, в том числе библиотекой BLAS.

Вопрос:

Разрешается ли модифицировать систему охлаждения на модуле NM Mezzo PCIe/104 ?

Ответ:

Модуль NM Mezzo PCIe/104 поставляется в 2 вариантах исполнения – без радиатора и с радиатором.

Кастомизация комплектного радиатора не предусмотрена.

Но потребитель всегда может спроектировать свой вариант системы охлаждения с учётом требований по съёму тепла с горячих элементов, указанных в ГЧ.

В качестве референса предлагается использовать 3D модель модуля с радиатором, представленную на сайте.

<https://www.module.ru/products/2-moduli/modul-nm-mezzo-pcie104>.

Вопрос:

Тестировались ли модули NM Mezzo PCIe/104 на температурные характеристики ?

Ответ:

Опытные образцы модуля прошли предварительные испытания, включая проверку стойкости на воздействие пониженной (-40°C) и повышенной (+70°C) температуры окружающей среды.

При этом, в качестве системы охлаждения использовался штатный радиатор.

Циркуляция воздуха в камере обеспечивалась вентилятором термокамеры, который подаёт горячий воздух.

В качестве прикладной задачи для обеспечения максимального энергопотребления была запущена нейронная сеть класса YOLO. При этом потребляемая модулем мощность составляла в НКУ порядка 12-13 Вт.

Вопрос:

Существуют ли варианты индустриального исполнения модуля NM Mezzo Mini (в основном интересует отрицательный температурный диапазон) ?

Ответ:

Все наши модули тестировали в индустриальном температурном диапазоне – от -40 до +85 °С.

Они работают с небольшими оговорками – на плюсе требуется обдув, для конвекции воздуха в объёме, где расположен модуль. NM Mezzo Mini в исполнении без радиатора должен иметь кондуктивный теплосъём на элементы конструкции аппаратуры, в которую он установлен.

Сейчас в документации прописан диапазон 0-40 °С. Это связано с тем, что документация на модуль разрабатывалась до появления продукта. Требования по температурному диапазону можно пересмотреть, но требуется провести дополнительные испытания.

Вопрос:

Подскажите, есть ли в продаже аналоги модуля MC189.01 ?

Ответ:

Аналогом данного изделия является модуль NM Mezzo Mini PCIe/104, обладающий более расширенным функционалом.

Вопрос:

Подскажите какой адаптер питания требуется для модуля MB164.01 ?

Ответ:

Вместе с модулем MB164.01 в комплекте поставки идёт адаптер питания на 12В.

Вопрос:

Есть ли тесты на частотные параметры PCI-E при работе с NM Mezzo PCIe/104 ?

Ответ:

Нет, таких тестов не проводилось.

Модуль через адаптер подключался к различным материнским платам из состава офисных ПК.

Со стороны модуля - контроллер «PCIe gen 2» - это часть микросхемы K1879BM8Я.

Вопрос:

Есть ли тесты по питанию при работе с модулем NM Mezzo PCIe/104 ?

Ответ:

Потребляемая модулем мощность составляет в НКУ порядка 12-13 Вт.

Вопрос:

Чем визуально отличаются исполнения NM Mezzo Mini ?

Ответ:

Исполнение NM Mezzo Mini можно определить по внешнему виду.

Без радиатора:

базовое исполнение (с SD-картой) и -02 (без SD-карты)

С радиатором:

исполнения -01 (с SD-картой) и -03 (без SD-карты)

В комплекте поставки платы есть этикетка. На ней также можно посмотреть вариант исполнения модуля.

Вопрос:

Разрешается ли установка дополнительных систем для мониторинга на плату NM Mezzo PCIe/104 ?

Ответ:

Такая установка не предусмотрена в конструкции.

Вопрос изменения конструктива требует дополнительного обсуждения.

Сейчас модули изготовлены в статусе опытных образцов, по результатам отработки которых запланирована корректировка документации. Можно что-то добавить, если это покажется целесообразным.

Вопрос:

Есть ли принципиальная и монтажная схема платы NM Mezzo PCIe/104 (хотя бы с описанием расположения элементов)?

Ответ:

Вся конструкторская документация кроме той, которая представлена на сайте (<https://www.module.ru/products/2-moduli/modul-nm-mezzo-pcie104>) - не передаётся.

Вопросы по ПО и драйверам и структуре архитектуры

Вопрос:

Под управлением какой ОС работают модули на базе СБИС K1879BM8Я?

Ответ:

Поддерживаются все ОС (Windows 7-10, Linux, Астра Linux, Эльбрус), однако под каждую платформу (host PCB) понадобится патч на прошивку. В течение дня делается патч драйвера под эту версию. Проверка производится при установке ПО поддержки модуля.

Вопрос:

Есть ли поддержка OpenCL для MC127.05?

Ответ:

Нет.

Вопрос:

Можно ли использовать SDK на хостовой системе Debian 11 под arm64?

Ответ:

Нет, SDK собран под архитектуру x86.

Совет:

Вы можете скомпилировать код под NMC на машине под x86. Установить драйвера (включая Библиотеку загрузки и обмена) и запустить на ARM-хосте скомпилированный код.

Вопрос:

Реализована ли поддержка прерываний legacy на шине PCI-e у процессора K1879BM8Я?

Ответ:

Да, реализована.

Вопрос:

Запуск любого кода на arm/nm осуществляется по PCIe+питание?

Ответ:

Да, работает через PCIe.

Вопрос:

Для каких кейсов используется Ethernet и microSD карта?

Ответ:

Ethernet для обмена данными с внешними устройствами (например, необработанные данные поступают на модуль по PCI-e шине, а обработанные данные выдаются по Ethernet-интерфейсу). Если требуется работа устройства без внешнего ЦПУ, можно загрузить образ ОС на SD-карту и запускать ОС на центральном Arm-ядре процессора 1879BM8Я.

Вопрос:

Можно ли логику управления процессом расчета реализовать на внешнем хосте при этом задействовать для вычислений NM ядра?

Ответ:

Да, это типовая схема работы устройства.

Вопрос:

Есть ли возможность из arm программы запускать программу на nm?

Ответ:

Такой сценарий возможен, но это не типовая схема работы устройства.

Совет:

Если нужно провести запуск программы не с хоста советуем пользоваться модулем NM Mezzo/NM Mezzo Mini:

<https://www.module.ru/products/2-moduli/128-nm-mezzo-mini>

Вопрос:

Возможно ли совместное использование NMDL SDK и пользовательских приложений для ARM/NM ядер?

Ответ:

Нет, совместное использование невозможно.

Совет:

Задача NMDL избавить разработчика от использования SDK и написания приложений на ARM/NM. Можно использовать центральный ARM процессор в качестве хоста для NMDL, но это требует доработок ПО.

Вопрос:

Подскажите по какой причине при использовании NM Pilot появляется проблема с меняющимся MAC адресом сетевого интерфейса ?

Ответ:

Mac адрес изменяется в связи с тем, что микросхема отвечающая за хранение этой информации (LAN7430) - не запрограммирована.

Вопрос:

Что необходимо для получения статического MAC адрес во время работы с NM Pilot ?

Ответ:

Для получения статического адреса необходимо запрограммировать микросхему Microchip LAN7430. Данный процесс описан в руководстве по программированию (раздел 2.4). Решение о том, какой MAC-адрес использовать остаётся за пользователем

Если же речь идёт про NM Pilot второй версии от зав.№008 и выше - то там будет заготовленный файл, в котором надо будет поменять значение MAC-адреса.

Вопрос:

Есть ли примеры взаимодействия процессов внутри процессора NM между NM процессорами и ПО в основной системе ?

Ответ:

Да, есть примеры работы с БЗиО. Они установлены вместе с ПО поддержки нейросетевых ускорителей NeuroMatrix в каталоге «example».

Вопрос:

Подскажите есть ли у вас информация по ядру сборки и файловой системе модуля NM Mezzo Mini ?

Ответ:

Файловая система от debian 11, т.е. все прикладные программы (для userspace) берутся с официального репозитория Debian.

А вот ядро Linux - это то , что портировалось разработчиками НТЦ "Модуль". Оно никак не привязано к debian 11.

К сожалению, взять любое другое ядро и запустить его на процессоре K1879BM8Я - нельзя. Ядро, которое идет в составе ОС для модуля NM Mezzo Mini адаптировалось под архитектурные особенности процессора и его внутренних функциональных блоков.

Переход на другую версию ядра не рассматривался в ближайшем времени.

Вопрос:

**Какие из перечисленных ОС поддерживаются :
Эльбрус 6.01-6.02, Астра Линукс 1.6, Альт Линукс 9 ?**

Ответ:

Поддерживаются все ОС, однако под каждую конкретную платформу (host PCB) понадобится патч на прошивку модуля NM Card

Если имеющийся у нас драйвер не собирается на какой-либо версии ядра, делается патч под необходимую версию в течение дня после обращения в службу технической поддержки. Проверить можно просто попыткой установки ПО поддержки модуля.

Вопрос:

Есть ли поддержка OpenCL для MC127.05 ?

Ответ:

Да, OpenCL есть.

Вопрос:

В руководстве по эксплуатации на микросхему K1879BM8Я написано, что адрес буфера пакета размещается в дескрипторе со 2 по 31 биты. Означает ли это, что адрес нужно сдвинуть вправо на 2 разряда потеряв при этом два старших разряда? Или адрес пишется в дескриптор без сдвига, но младшие два бита всегда должны быть нулевыми? Драйвер GRETH (RTEMS, Linux) не делает сдвигов адресов. Я пробовал оба варианта.

Ответ:

Это означает, что адрес буфера должен быть кратен 4. Адрес сдвигать не надо.

Вопрос:

Адрес таблицы, судя по руководству по эксплуатации на микросхему K1879BM8Я, пишется в регистр GRETH_TPTR с 10 по 31 разряды. Означает ли это, что адрес таблицы должен быть сдвинут вправо на 10, потеряв при этом старшие 10 разрядов?

Ответ:

Это означает, что таблица дескрипторов должна быть выровнена по границе 1КБ и не должна пересекать ее. 3 младших бита не используются, так как дескриптор занимает 8 байт, а адреса дескрипторов должны быть кратны 8.

Вопрос:

Могут ли выделенные под таблицу дескрипторов и буфер фрейма области памяти находиться в любом регионе памяти или в строго определённых?

Надо ли делать какое-то преобразование адресов между адресными пространствами?

Надо ли добавлять барьеры памяти после записи данных дескрипторов?

Ответ:

Если самостоятельно не настраивать виртуальную память, то ARM работает с физическими адресами (код U-boot тоже работает без MMU). Буфера и дескрипторы могут быть в любых регионах (при условии, что DDR настроена).

Можно делать барьеры, чтобы гарантировать, что данные уже в памяти перед запуском аппаратуры и избежать переупорядочивания операций, которые может исполнить компилятор. После получения работающего кода, барьеры можно убрать, если это не нарушает работу программы.

Вопрос:

Существуют ли для процессора K1879BM8Я специализированные библиотеки (например поддержка систолических массивов) ?

Как реализовано ускорение матричных ускорений ?

Ответ:

Архитектура процессора K1879BM8Я представляет кластерную структуру из 4 кластеров по четыре NMC4 ядра в каждом.

В свою очередь каждое NMC4 ядро содержит 4 вычислительных ячейки , выполняющих элементарное векторно-матричное умножение за такт. Результаты произведений аккумулируются в соответствующих векторных регистрах каждого ядра.

Применительно к задаче матричных вычислений , в частности перемножения матриц , каждое из 16 ядер , накапливает частичное произведение фрагментов матриц в собственной внутренней памяти и далее результаты передаются соседним ядрам по принципу карусели для дальнейшего накопления и формирования окончательного результата.

Таким образом, мы условно имеем: матрицу процессорных элементов , разбиение исходных данных на подматрицы и конвейерный процесс вычислений.

В этом смысле можно говорить как об обработке систолических массивов.

Вопрос:

Есть ли прогноз по появлению специализированных библиотек для NPU?

Ответ:

Библиотечную поддержку систолических массивов в универсальном виде затруднительно в виду большого числа как самих функций, так и специфик задач, которые накладывают различные ограничения.

Поэтому предоставляются, так называемые, примитивы векторных функций (оптимизированных на ассемблере) для одного ядра.

Пользователь в свою очередь самостоятельно раскладывает их на нужные ядра, либо может использовать в качестве прототипа для реализации собственных функций. Библиотеки предоставляются с открытым исходным кодом.

В виду невозможности покрыть все векторно-матричные функции-практикуется реализация под запрос.

Если недостающая функция вписывается в состав библиотеки, то можно рассмотреть реализацию своими силами.

Вопрос:

Есть вопрос по NM Mezzo mini про возможность работать под управлением Linux на локальном кластере Cortex-A

Ответ:



У нас есть рабочий вариант ОС Линукс под модуль **NM Mezzo Mini**, но эта версия не доведена до стадии продукта. Сейчас ведутся работы по разработке драйвера для работы с кластерами вычислителей. Опять же есть рабочий вариант, идёт доработка и тестирование.

Вопросы по инициализации, загрузке и диагностике

Вопрос:

При установке NM Card в новую машину, плата не распознается как «Мультимедийное устройство» или «PCI-устройство». Вместо этого NM Card отображается в диспетчере как «Неизвестное устройство».

При установке Neuromatrix_accelerators_support.exe в открывшемся окне командной строки никакие устройства не находятся.



Что нужно сделать чтобы NM Card распознался?

Ответ:

- 1) Открыть консоль от имени администратора.
- 2) Перейти в папку C:\Program Files\Module\NMCard\drv
- 3) Запустить PnPUtil.exe -i -a nm_card_pci.inf
- 4) Перейти в папку C:\Program Files\Module\NMCard\drv_fit
- 5) Запустить PnPUtil.exe -i -a nm6408_br_pcie_fit.inf

Вопрос:

В соответствии с руководством по эксплуатации были установлены драйвера на изделие Модуль NM Card к ПК и программный модуль Neuromatrix Deep Learning (NMDL).

Модуль NM Card корректно отображается в системном окне "Управление устройством" (Изображение 1), но при попытке запуска программы-примера, приведенной в руководстве пользователя к программному модулю NMDL (размещен по ссылке <https://www.module.ru/uploads/pages/nmdlru-3f2616d04b.pdf>), программа выдает ошибку: "Initialize: BOARD_RESET_ERROR" (полный вывод программы приведен на Изображении 2).

Такая же ошибка (NMDL_RESULT_BOARD_RESET_ERROR) возникает при попытке запустить модель с помощью NM Card и при нажатии на "Blink" в GUI, поставляемом совместно с NMDL.

В руководстве пользователя приведен только дословный перевод ошибки в качестве пояснения, но никаких возможных причин или вариантов решения данной проблемы там нет.

Какие необходимо принять меры для устранения данной проблемы?

Ответ:

Попробуйте следующее:

- 1) Открыть «Диспетчер устройств».
- 2) Выбрать одно из установленных устройств NM_CARD.

3) В главном окне «Диспетчер устройств» выбрать «Вид» -> «Устройства по подключению».



4) В измененной иерархии устройств найти необходимый NM_CARD, затем правой кнопкой мыши выбрать «Мост PCI-PCI», к которому он подключен, и выбрать «Свойства»-> «Драйвер» -> «Сведения».

5) Если информация отображается как на приложенном скриншоте 1, то: В папке, куда установлено БЗиО (по умолчанию C:\Program Files\Module\NMCard\libload\bin) есть файл, который называется «nm6408_set_br_pcieflt.exe».

Его надо запустить, потом перезагрузить компьютер и еще раз оценить информацию во в окне «Сведения».

Если ничего не изменилось, то запустить этот же файл из консоли открытой под администратором или просто запустить от имени администратора.

На приложенном скриншоте 2 продемонстрировано окно «Сведения» с корректной информацией. Следует добиваться именно этого случая. NMDL запустить от имени администратора!



Вопрос:

Инструкция по работе с YOLOv5 в NMDL ?

Ответ:

1. Получение модели в формате ONNX

Предобученную сеть можно взять из репозитория, например: YOLOv5 v6.0 -> Releases -> Assets -> yolov5s.pt (<https://github.com/ultralytics/yolov5/releases/tag/v6.0>) и переобучить на своих данных. Затем сконвертировать модель pytorch в ONNX: `python export.py --weights your_yolov5s.pt --include onnx`, как описано в инструкции:

https://docs.ultralytics.com/yolov5/tutorials/model_export/#export-a-trained-yolov5-model

2. Подготовка модифицированной модели

Для получения модели, которую воспринимает NMDL, воспользуйтесь скриптом `modify_model_yolov5.py` (в приложении к документу).

а) Задайте в переменной `input_path` имя входного Onnx файла, `output_path` – выходного. б) Задайте в `input_names` имя входа как в модели. Задайте в `output_names` названия выходов 3-х последних сверток как в модели (для других версий YOLOv5 (например v.6.2), имена выходов могут отличаться). В программе Netron (<https://github.com/lutzroeder/netron>) можно посмотреть (model properties) названия входов и выходов, а также их размеры. в) Задайте размеры `WIDTH`, `HEIGHT` входного изображения чтобы их зафиксировать.

```
import sys
import onnx
from onnx.tools import update_model_dims
from onnxsim import simplify
input_path = 'yolov5s.onnx'
output_path = 'yolov5s_modified.onnx'
input_names = ['images']
output_names = ['474', '622', '326']
BATCH = 1
CHANNEL = 3
HEIGHT = 1920
WIDTH = 1088
onnx.checker.check_model(input_path)
model = onnx.load(input_path)
e = onnx.utils.Extractor(model)
extracted = e.extract_model(input_names, output_names)
onnx.checker.check_model(extracted)
static_length_model =
update_model_dims.update_inputs_outputs_dims(extracted,
{input_names[0]: [int(BATCH), int(CHANNEL), int(HEIGHT), int(WIDTH)]},
{output_names[0]: ['B', 'C','H','W'], output_names[1]: ['B', 'C','H','W'],
output_names[2]: ['B', 'C','H','W']})
onnx.checker.check_model(static_length_model)
model_simp, check = simplify(static_length_model)
assert check, "Simplified ONNX model could not be validated"
# Save the ONNX model
onnx.save(model_simp, output_path)
```

3. Портирование под NM-card.

Чтобы сконвертировать полученный ONNX файл «yolov5s_modified.onnx» в формат NMDL *.nm8 , нужно воспользоваться программой nmdl_compiler_console из дистрибутива NMDL.

Для этого вызвать в командной строке программу

nmdl_compiler_console из установочной директории NMDL в каталоге bin (NMDL\bin) с такими параметрами:

```
path_to_nmdl/bin/nmdl_compiler_console MC12705 ONNX
```

```
yolov5s_modified.onnx model.nm8 0
```

```
path_to_nmdl/bin/nmdl_compiler_console MC12705 ONNX
```

```
yolov5s_modified.onnx model_mu.nm8 1
```

В первой строке примера получается файл *.nm8 для работы в режиме single_unit, во второй строке для режима multi_unit.

4. Постобработка на хосте.

Результатом обработки первой части модели на NM-card будут 3 тензора, соответствующие трем последним сверткам в исходной onnx модели. Вторая часть модели выполняется на хосте и представлена в файле detection_results.hpp. В этом файле собраны все необходимые функции для выполнения второй части модели в классе DetectionResults:

```
GetBoxes(const std::vector<std::vector<float>>& scores, const  
S_NetworkInfo& network_info)
```

5. Приложение NMDL GUI.

В приложении NMDL GUI можно протестировать результат работы первой части модели, вторая часть (хостовая) уже встроена в постобработку. Для работы с NMDL GUI нужно подготовить настроечный файл discription.xml (пример в приложении к документу для YOLOv5 версии v6.0 для базы данных MS COCO), в котором указать тип модели "yolo5" и другие параметры. Здесь приводится фрагмент из «NMDL Руководство пользователя», раздела который относится к .xml файлу.

Описание нейронной сети осуществляется в формате XML и содержит информацию о необходимом формате изображения, а также параметры интерпретации выходных параметров.

model - Строка с названием файла модели нейронной сети в одном из следующих форматах:

*.nm7 - описание модели для загрузки на модули MC121.01 и NMStick.

*.nm8 - описание модели для загрузки на модули MC127.05, NMCard или на симулятор.

*.onnx или *.onnx - описание модели в формате ONNX Protobuf. Модель может быть загружена на любой модуль. Перед загрузкой на модуль модель предварительно конвертируется в *.nm7 или в *.nm8 в зависимости от типа модуля.

*.cfg - описание модели в формате DARKNET.

Файл с весовыми коэффициентами *.weights должен размещаться в том же каталоге и иметь то же название, что и файл описания модели *.cfg. Модель может быть загружена на любой модуль. Перед загрузкой на модуль модель предварительно конвертируется в *.nm7 или в *.nm8 в зависимости от типа модуля.

Можно указать как абсолютный путь к файлу, так и путь, относительно размещения файла описания XML.

format - Формат пикселя, к которому будет преобразованы пиксели входного изображения перед обработкой. Может принимать значения:

- rgb
- rbg
- grb
- gbr
- brg
- bgr

Это значение соответствует порядку следования каналов входного тензора.

divider - Масштабирующий коэффициент для каждой цветовой компоненты пикселя входного изображения. Используется при преобразовании изображения во входной тензор (см. раздел "Подготовка изображений").

adder - Коэффициент смещения для каждой цветовой компоненты пикселя входного изображения. Используется при преобразовании изображения во входной тензор (см. раздел "Подготовка изображений").

neural_network - Выбранная нейронная сеть. Может принимать значения:

- classifier - нейронная сеть - классификатор, например ALEXNET, RESNET, SQUEEZENET.
- unet - нейронная сеть семейства U-Net.
- yolo2 - нейронная сеть семейства YOLO V2.
- yolo3 - нейронная сеть семейства YOLO V3.
- yolo5 - нейронная сеть семейства YOLO V5.

Результатом работы классификатора является вектор вероятностей принадлежности изображения определённым классам. В демонстрационной программе классы и вероятности обнаружения выводятся во всплывающем окне.

Сети YOLO в результате обработки выдают информацию о нескольких обнаруженных объектах и их расположении на исходном изображении. В демонстрационной программе обнаруженные объекты обозначаются непосредственно на исходном изображении в описывающих прямоугольниках.

yolo_anchors - Параметры начальной инициализации детектируемых прямоугольников (только для сетей YOLO).

yolo_confidence_threshold - Порог для отображения результатов детектирования (только для сетей YOLO).

yolo_iou_threshold - Порог пересекающихся прямоугольников детектирования (только для сетей YOLO)

labels - Список строк с названиями классов, которые будут отображаться в окне результата обработки.

Вопрос:

У нас на руках модуль 1879BM8Я с sd-картой и MB164.01.

Для работы процессора в ПЛК нам необходимо, чтобы ОС запускалась на 1...5 ARM-ядрах. Остальные 16 DSP ядер подключались по необходимости для решения разных задач из этой самостоятельной ОС.

Хочется запустить ОС, подключившись к отладочному UART процессора.

Какой UART использовать? Тот что RS232 на разъёме X3?

Какой вариант загрузки выставлять? Варианта с sd-карты нет ?

Ответ:

Модуль по умолчанию грузится с spi ПЗУ, потом с sd карты

Рекомендации по начальной загрузке по вашему сценарию:

Режим загрузки должен быть выставлен следующий:

Подключаться надо к разъёму X3 на плате

Скорость 115200

Стоповых бит 1

Бит Четности отсутствует

Битов данных 8.

Вопрос:

Работая с модулем MC127.05, пытаемся использовать SDK на хостовой системе Debian 11 под arm(Байкал)

Скажите пожалуйста, ваша система рассчитана для запуска под arm64?

Ответ:

SDK работать не будет и компилятор nm-gcc тоже

Существующий SDK собран под архитектуру x86.

Вы можете скомпилировать код под NMC на машине под x86. Установить драйвера (включая Библиотеку загрузки и обмена) и запустить на ARM-хосте скомпилированный код.

Вопрос:

Имеются ли у разработчиков указанной платы (MC127.05) средства для диагностики / самодиагностики на предмет работоспособности аппаратной части и прошивки указанного модуля ?

Ответ:

Инструментов для диагностики и самодиагностики у нас нет.

Вопрос:

Вопрос про нестабильность работы:

ОС зависла пару раз. Возможно дело в несовместимости systemd и версии ядра, как минимум ошибки запуска об этом говорят.

Радиатор большой поставлен, вряд ли дело в перегреве.

Ответ:

Сложно сказать почему ОС могла зависнуть. Несовместимость systemd и версии ядра это очень обширная формулировка. Если есть какие то уточнения в виде логов, то можно и нужно изучить проблему детальнее. Просим их предоставить, по возможности.

Так как нет конкретики - тут может быть что угодно, от некачественного питания изделия (возможно бывают просадки по напряжению) до проблем с картой памяти microSD.

Systemd от Debian 11 по умолчанию совместим с ядрами начиная с 5 версии, но не исключено, что тут могут всплыть подводные камни.

Вопрос:

Сборка работает на 1 ядре. Как задействовать остальные 4 и как из системы работать с NeuroMatrixCore ?

Ответ:

Ядро Linux работает только на одном ядре. Центральный ARM. 4 кластерных ядра используются для взаимодействия с NeuroMatrixCore.

Для взаимодействия с NeuroMatrixCore в ядре имеется драйвер, а для прикладных задач в Rootfs используется библиотека загрузки и обмена. Она установлена в /usr/local/rc_module/board-nm6408

Пользователь в ОС работает с NM ядрами - либо через библиотеку NMDL, либо напрямую через библиотеку загрузки и обмена.

Примечание: при необходимости запуска нейронных сетей, нужен только интерфейс с NMDL, и он есть.

Вопрос:

Подскажите, есть ли у вас информация по ядру сборки и файловой системе ?

Ответ:

Файловая система используется от debian 11, т.е. все прикладные программы (для userspace) берутся с официального репозитория Debian.

А вот ядро Linux - это то, что портировалось разработчиками HTC "Модуль". Оно никак не привязано к debian 11.

К сожалению, взять любое другое ядро и запустить его на процессоре K1879BM8Я - нельзя. Ядро, которое идет в составе ОС для модуля NM Mezzo Mini адаптировалось под архитектурные особенности процессора и его внутренних функциональных блоков.

Переход на другую версию ядра не рассматривался в ближайшем времени.

Вопрос:

Программно эти объединённые модули можно использовать для инференса одной модели?

Т.е. с увеличением стека уменьшается ли latency инференса?

Ответ:

Да! Такая задача на несколько вычислительных модулей Mezzo - решена!

Тяжёлые сети хорошо распараллеливаются на несколько модулей, но Latency при этом не уменьшается, а растёт показатель FPS.


Хочется подчеркнуть, что Latency – это время (задержка) до получения решения, а не величина обратная FPS.

В данном случае узким местом будет пропускная способность шины PCIe 2.0 x4, которая является для нашего чипа системной шиной.


Краткое описание последовательности установки ПО поддержки

Установка ПО под Linux


1. В терминале набрать `sudo dpkg -i NeuromatrixAcceleratorsSupport.deb`. Это команда разархивирует deb пакет и автоматически загрузит инсталлятор.




2. Появляется меню выбора ПО для устанавливаемого модуля. Необходимо выбрать нужный модуль из списка и установить.




3. Проверить корректную установку ПО необходимо в терминале командой `checkinstall.sh` «название модуля».




Папка с установленными библиотеками должна выглядеть следующим образом:



4. В случае если ПО уже установлено, но его нужно переустановить для другого модуля (к примеру, стоит ПО для NM Card, а установить надо ПО для NM Mezzo), то необходимо запустить установку заново: `sudo dpkg -i NeuromatrixAcceleratorsSupport.deb`. Отобразится меню удаления пакетов (`delete_all` - удаляет все и ставит выбранный пакет, или `not_delete` - ранее установленное ПО остается и ставится выбранный пакет).




5. Для удаления всех пакетов из системы необходимо выполнить: `sudo dpkg -i NeuromatrixAcceleratorsSupport.deb`




Установка ПО под Windows


1. Деинсталлировать ПО и перезагрузить компьютер.




Если в системе остался драйвер, необходимо удалить его вручную.



Обновить конфигурацию оборудования.




Если все ранее установленные драйверы из системы удалены, останется неизвестное устройство.




Перезагружаемся.


1. Выполнить инсталляцию и перезагрузить компьютер.




Следовать всем пунктам по умолчанию и установить драйвер.




Установить фильтр для моста, к которому подключена плата (нажать любую клавишу).




Выведется информация о найденных платах.



Продолжаем установку и перепрошиваем плату (>all и нажимаем ввод).





Продолжаем установку.





Перезагружаемся.


2. Проверяем корректность установки.




Проверяем, что у моста стоит фильтр (отображаем устройства по подключениям).




Открываем редактор реестра и ищем
HKEY_LOCAL_MACHINE ---> SYSTEM ---> Current Control Set --->Services.




Проверяем, что драйвера лежат в ожидаемом месте (как указано в ImagePath в редакторе реестра).




Проверяем переменные среды (NM_Card).




Проверяем версию библиотеки.



Запускаем командную строку от имени администратора и переходим в место установки (каталог libload).




Запускаем утилиту проверяющую корректность установки фильтра.



Далее запускаем тестовую программу (консоль открыта от имени администратора).

Переменная PATH должна содержать путь до dll: > echo %PATH%

...;C:\Program Files\Module\NMCard\libload\bin;...



```
Администратор: C:\Windows\System32\cmd.exe
1 NM6408 board(s) found.
0 filter driver(s) added.
1 filter driver(s) found already setted.
0 error(s) detected.

C:\Program Files\Module\NMCard\libload>nm_card_run -c0 -n0 simple.abs
Batch loader for NM_Card v3.0. (C) 2021 RG Module Inc.
Firmware v1.2
Start user program on core 0.0...
simple.abs :: Core 0.0 return 3628800 = 0x375F00.

C:\Program Files\Module\NMCard\libload>nm_card_run -c0 -n0 simple.abs
Batch loader for NM_Card v3.0. (C) 2021 RG Module Inc.
Firmware v1.2
Start user program on core 0.0...
simple.abs :: Core 0.0 return 3628800 = 0x375F00.

C:\Program Files\Module\NMCard\libload>nm_card_run -c0 -n0 simple.abs
Batch loader for NM_Card v3.0. (C) 2021 RG Module Inc.
Firmware v1.2
Start user program on core 0.0...
simple.abs :: Core 0.0 return 3628800 = 0x375F00.

C:\Program Files\Module\NMCard\libload>
```

Вопросы по производительности NMC4 для БПФ

Вопрос:

Возможна ли работа инструментального модуля MC127.05 с вычислительным шасси с архитектурой Эльбрус 4Э8СВ-MSWТХ? Сколько модулей допустимо использовать с шасси?

Ответ:

Да, с 4х-процессорной платой Эльбрус может быть сопряжено до 4 модулей NM Card.

Вопрос:

В таблице (см. приложение 1) указаны характеристики производительности процессора для тактовой частоты NMC4 равной 500 МГц, но как указано в руководстве по эксплуатации рабочая тактовая частота NMC4 равна 1000 МГц. Какова производительность процессора с учетом рабочей тактовой частоты?

Ответ:

В таблице частота 500МГц указана для процессора 1879ВМ6Я (NM6407) с ядром nmc4. Производительность всех функций измерена при работе с внутренней памятью.

Производительность одного ядра процессора 1879ВМ8Я с той же архитектурой NMC4 на тех же задачах, но уже с частотой 1ГГц соответственно будет ровно вдвое выше.

Вопрос:

Характеристики для NMC4, приведенные в таблице (см. приложение 1), являются характеристиками для одного NMC4 ядра или это суммарные характеристики для всех 16-ти ядер NMC4 ядер?

Ответ:

Производительность всех функций приводится для одного ядра NMC4. Многоядерные реализации достаточно специфичны в контексте общей задачи и именно как библиотечные функции пока нами не практикуются.

Вопрос:

В наших алгоритмах задействовано обратное преобразование Фурье (ОБПФ), но оно не отражено в вашей таблице (см. приложение 1). Какова производительность для ОБПФ для данных типа float?

Ответ:

Реализация БПФ – единая, что для прямого, что для обратного преобразования. Разница только в коэффициентах. По скорости они одинаковые.

Вопрос:

В таблице (см. приложение 1) дана производительность для вейвлет – преобразования для данных с фиксированной точкой. Какова производительность для вейвлет – преобразования с данными типа float?

Ответ:

Вейвлет преобразования на float мы не делали в виду отсутствия такой задачи. Если такая функция необходима, то нужен запрос. Грубая оценка производительности «на бумаге» возможна если будет соответствующая конкретизация.

Вопрос:

Где можно найти библиотечные функции или ассемблерный код для (БПФ и ОБПФ) юд ядра NMC4? Эти функции необходимы нам для тестирования разработанных нами алгоритмов на тестовой плате MC127.05.

Ответ:

БПФ входит в состав библиотеки nmpp. Она доступна по адресу <https://github.com/rc-module/nmpp/>. В библиотеке сейчас производится рефакторинг. Некоторые тесты и примеры, в т.ч. на БПФ в данный момент могут иметь проблемы со сборкой на MC127.05.

Приложение 1

Производительность для ядра NMC4 с плавающей точкой

Тест		Объем данных	Ядро NMC4 с тактовой частотой 500 МГц		
			Такты	Тактов на точку	Время выполнения, мкс
Быстрое преобразование Фурье (БПФ) над complex real – float, im - float		128	1091	8.5	2.2
		256	1763	6.9	3.5
		512	3675	7.2	7.3
		1024	8647	8.4	17.3
		2048	19504	9.5	39.0
		4096	54258	13.2	108.5
Умножение матриц с элементами одинарной точности (SGEMM) [A] * [B]		128x128	139929	8.5	279.9
Медианный фильтр с размером окна – 3 точки (double)		1024	3353	3.3	6.7
Поэлементное умножение векторов с накоплением A.*B+C	double	2000	2076	1	4.1
	complex	2000	2076	1	4.1
	float	2000	1085	0.5	2.2
Быстрое преобразование Фурье (БПФ)		256	2742	11	5.5
		512	6500	13	13
		1024	18400	10	36.8
Умножение матриц целых чисел (32 бита) [A] * [B] + [C]		128x128	573440	35	1147
Двумерное искретное косинусное преобразование (ДКП) 8x8		Кадр 128x128	20215	1.2	40.4

Тест	Объем данных	Ядро NMC4 с тактовой частотой 500 МГц		
		Такты	Тактов на точку	Время выполнения, мкс
Вейвлет-преобразование (ВП), 1 степень	Кадр 128x128	26200	1.6	52.4
Фильтр Собеля	Кадр 128x128	44237	2.7	88.5
Медианный фильтр 3x3	Кадр 128x128	147456	9	295
КИХ-фильтр 5x5	Кадр 128x128	40960	2.5	82
Дискретное преобразование Уолша-Адамара	1024	2252	2.2	4.5

Вопросы по объединению и распараллеливанию

Вопрос:

Какой стек максимально можно составить из этих модулей? Как они соединяются между собой?

Ответ:

Системные разъёмы форм-фактора NM Mezzo PCIe/104 имеют вариации.

У нас реализован вариант, когда через разъёмы устройства идут 2 шины PCIe x4 и 4 шины PCIe x1. На наш чип заходит одна шина PCIe x4, а вторая идёт транзитом на следующие модули.

Отвечаю на Ваш вопрос – в стекап можно собрать 2 однотипных модуля NM Mezzo PCIe/104. При этом 4 шины PCIe x1 идёт транзитом через оба модуля.

Модули могут располагаться относительно модуля с CPU в любой вариации – как снизу, так и сверху. Могут сочленяться друг с другом подряд. Но модули теплонагруженные, лучше их разнести в блоке. При этом с программной точки зрения при использовании пакета NMDL+ можно распараллеливать работу одной ИНС на 2 модуля. При этом, Latency не уменьшится.

Вопрос:

Программно эти объединённые модули можно использовать для инференса одной модели?

Т.е. с увеличением стека уменьшается ли latency инференса?

Ответ:

Да! Такая задача на несколько вычислительных модулей NM Mezzo - решена!

Тяжёлые сети хорошо распараллеливаются на несколько модулей, но Latency при этом не уменьшается, а растёт показатель FPS.

Хочется подчеркнуть, что Latency – это время (задержка) до получения решения, а не величина обратная FPS.

В данном случае узким местом будет пропускная способность шины PCIe 2.0 x4, которая является для нашего чипа системной шиной.

Несколько лет назад мы с партнёрами сделали сервер, в котором стояли 12 NM Mezzo Mini. Решение работало, но в серию не пошло. При необходимости можно воспроизвести.

Вопрос:

Возможно ли программно объединить четыре модуля Mezzo в один четверённый вычислитель?

Ответ:

У нас нет опытов с реализацией четырехпроцессорного модуля на основе NM Mezzo.

Однако у нас есть устройство NM Mezzo PCIe/104 , которое обеспечивает стекап:

<https://www.module.ru/products/2-moduli/modul-nm-mezzo-pcie104>

Вопрос:

Есть ли опыт объединения ваших устройств через External Link?

Ответ:

Говоря про модуль NM Mezzo - опыта объединения не было, т.к. там попросту нет интерфейса External Link

Для справки:

Если же говорить про модули NM Card и NM Quad, то у опыт объединения NM Card через External Link имеется.

Отвечая на вопрос:

Был ли опыт - да был.

Вопрос:

Верно ли что NM Quad и 4 Mezzo отдельных Mezzo (у каждой свои PCI-E x4) будут давать одинаковый FPS на одной модели, при условии что в одном случае мы кормим всем по одному целому кадру ?

Ответ:

Скорее всего в общем случае 4 NM Mezzo будут работать быстрее, чем 1 NM Quad. В NM Quad стоит PCIe хаб x4 <-> 4 по x1.

В итоге информационный канал между CPU и нашими чипами имеет в 4 раза меньшую пропускную способность.

Для тяжёлых моделей - это не является узким местом, т.к. процессор считает достаточно долгое время по сравнению с транзакциями по шине.

Вопрос:

Почему при наличии 4 *x1 PCI-E в исполнении PCIe/104 стек составляет только два модуля, это как-то связано с питанием?

Ответ:

2 модуля NM Mezzo PCIe/104 можно подключить к CPU по 2 шинам PCIe x4. Шины x1 идут транзитом и не приходят на чип.

Module