

УДК 004.272.57

## ОБРАБОТКА ИЗОБРАЖЕНИЙ В СИСТЕМЕ ТЕХНИЧЕСКОГО ЗРЕНИЯ С ИСПОЛЬЗОВАНИЕМ ВЫСОКОПРОИЗВОДИТЕЛЬНЫХ ВЫЧИСЛИТЕЛЬНЫХ ПЛАТФОРМ

### DEVELOPMENT AND RESEARCH OF METHODS AND ALGORITHMS SUBBAND INTERPOLATION AND EVALUATION OF DERIVATIVE IMAGES

**М.И. Иванов, С.А. Сорокин**  
**M.I. Ivanov, S.A. Sorokin**

*АО «Научно-исследовательский институт вычислительных комплексов им. М.А. Карцева»,  
Россия, 117437, Москва, ул. Профсоюзная, 108*

*JSC "Scientific-Research Institute of Computer Complex. M.A. Kartseva",  
108 Profsoyuznaya St., Moscow, 117437, Russia*

*e-mail: postoffice@niivk.ru*

*Аннотация.* В статье приводятся материалы по эффективному применению вычислительных возможностей, организации параллельно-конвейерной обработки информации ВГВП на примере системы обработки видео высокого разрешения в режиме реального времени.

*Resume.* This article contains material on the effective use of computing power, the organization of parallel-pipelined data VGVP video processing system an example of a high-resolution real-time.

*Ключевые слова:* высокопроизводительная гетерогенная вычислительная платформа (ВГВП), субполосная обработка изображений.

*Keywords:* high performance heterogeneous computing platform (VGVP) subband image processing.

При создании высокопроизводительной гетерогенной вычислительной платформы (ВГВП) одной из целей, преследуемой разработчиками, является создание вычислительной платформы, удобной как для построения новых вычислительных систем под конкретную задачу пользователя, так и для применения в уже существующих вычислительных системах и комплексах в качестве вычислительного спецоборудования, призванного усовершенствовать последние. Это означало, что создаваемая платформа должна отвечать следующим требованиям: быть реконфигурируемой, масштабируемой и иметь возможность поддержки вычислительных средств различной архитектуры. Платформа, удовлетворяющая этим требованиям, способна стать основой для построения вычислительных систем широкого спектра применения, и в то же время в частных случаях, для построения вычислителей, нацеленных на конкретную прикладную задачу.

В качестве прикладной проблемы разработчиками ВГВП может быть выбрана задача обработки изображений в режиме жесткого реального времени, поступающей по каналам связи от разнородных специализированных информационных систем. Исходя из этого, создаваемые вычислительные средства должны удовлетворять следующим принципам:

- Распределенные вычисления. Уход от централизованных вычислений с использованием одного хоста, использование множества независимых, равноправных вычислительных модулей различного функционального назначения, работающих с жесткой привязкой к временным меткам;
- Конвейеризация. Распределенные вычислительные модули строятся с применением конвейерных вычислений с минимизацией глубины конвейера;
- Минимизация потоков обмена. Применение алгоритмов работы вычислительных модулей, минимизирующих передачу данных между ними;
- Организация структуры транзитных данных. Использование алгоритмов реального времени, предполагающих пересечения большого количества коррелированных потоков данных «каждого с каждым» с жесткой привязкой к временным меткам. Результаты должны быть получены в жестко ограниченное время после окончания потока данных;
- Величины потоков данных и сложность обработки делают невозможным решение задачи на централизованных системах передачи с единым управлением. Поэтому здесь создается



сеть независимых вычислителей, работающих по принципу: «получил сам – поделись с ближним»;

- Синхронизация. Привязка к временным меткам внешней синхронизации или несколько синхросерий, поступающих на вычислительные модули распределенной архитектуры. Без этого совместная распределенная обработка данных в канальном интервале невозможна.

Рассмотренные выше принципы построения реализуют концепцию создания многомодульной архитектуры, в которой одновременно несколько вычислительных модулей с разнородной архитектурой могут параллельно обрабатывать информационные потоки.

Особый интерес представляют системные решения, где используются технологии, применяемые в микропроцессорах с архитектурой «Эльбрус», с использованием принципов обработки информации.

Исследования показали, что практически все программы обладают значительным потенциалом параллелизма на уровне операций (таких как арифметико-логические и обращения к памяти) — от нескольких десятков до нескольких тысяч операций за такт [Галаган, Тумакин, 2016]. Этот вид параллелизма наиболее универсален, он может быть эффективно поддержан в аппаратуре и обнаружен автоматически (с помощью компиляторов) в существующих программах. Векторный параллелизм (операции над упакованными данными) также поддается аппаратно-программной оптимизации, но имеет ограниченное применение в программах. Параллелизм потоков управления, реализуемый в многоядерных и многопроцессорных системах с общей памятью, значительно труднее поддается программной автоматизации и зачастую требует усилий программистов для явного распараллеливания программ. Таким образом, параллелизм на уровне операций является важнейшим методом повышения производительности процессорного ядра, вследствие чего повышается производительность многоядерных систем в целом, так как ускоряются вычисления на участках, не поддающихся другим видам распараллеливания.

Использование параллелизма операций и технологии динамической компиляции позволяет не только поднять производительность ядра процессора, но и при наличии аппаратной поддержки обеспечить эффективную совместимость с распространенными микропроцессорными архитектурами, что способствует преодолению ограничений в развитии архитектуры микропроцессоров, вызванных проблемами совместимости на уровне двоичных кодов.

Важнейшая особенность архитектуры «Эльбрус» - явное указание процессорному ядру на использование параллельности исполняемых операций, анализ независимости которых и их планирование выполняет компилятор. Это позволяет отказаться от сложной и энергоемкой аппаратуры обеспечения внеочередного исполнения команд, применяемой во всех современных универсальных микропроцессорах, и делает осмысленным расширение парка исполнительных устройств и повышение предельной производительности на такт до уровня, превосходящего возможности конкурирующих решений.

Следует отметить, что машинное зрение (machinevision) — это обширный прикладной раздел междисциплинарной теории компьютерного зрения (computervision), представляющий существенный потенциал для встраиваемых систем. Машинное зрение как инженерная дисциплина находится на стыке нескольких областей, таких как компьютерное зрение, встраиваемые системы, базы данных, машинное обучение. Среди многочисленных направлений применения наиболее обширные внедрения наблюдаются в области промышленных и военных применений по следующим направлениям: системы визуального контроля и управления; системы безопасности; системы виртуальной и дополненной реальности; технические средства высокой степени автономности - от пилотажно-навигационных подсистем БИУС и до полностью автономных роботизированных технических средств. Элементы технологий машинного зрения представляет собой взаимосвязанную технологическую последовательность, включающую следующие звенья: получение изображения от видеокамеры; обработку (оцифровку) изображения; логический анализ цифрового изображения и выделение нужной информации; перемещение камеры в пространстве. Видеокамера и устройство обработки изображения являются главными составляющими системы машинного зрения, их объединяет термин «техническое зрение».

Для подобных систем характерно наличие нескольких потоков структурно-разнородных данных (в первую очередь это видеопотоки от камеры высокого разрешения), необходимость приема данных в нестандартных форматах, необходимость максимизации быстродействия для обработки сценариев по предназначению системы в режиме реального времени.

Для обработки каждого из потоков данных целесообразно использовать ту архитектуру, которая будет эффективнее при обработке каждого из потоков данных. Например, для реализации ряда специальных прикладных алгоритмов или предварительной обработки нестандартных данных целесообразно использовать вычислитель на базе ПЛИС, для обработки интенсивных потоков видео — вычислители на базе графических процессоров, для решения задач контроля и принятия решений — вычислитель центрального процессора, и т.д.

Отечественная высокопроизводительная гетерогенная вычислительная платформа (ВГВП) позволяет строить и эффективно применять гетерогенные конфигурации. Выбор конкретной гетерогенной конфигурации обусловлен комплексом исходных технических требований, типом данных и режимов их обработки.

На базе ВГВП представляется возможным осуществлять конвейерную обработку данных с применением гетерогенной архитектуры. Идея использования гетерогенных вычислительных конвейеров заключается в том, чтобы на каждом этапе последовательной обработки (участке конвейера) обработчик на базе оптимальной для работы с конкретным типом данных архитектурой, выполнив свою работу, передавал бы результат для дальнейшей обработки на следующий участок конвейера для обработки вычислителем – обработчиком другой архитектуры, одновременно принимая новый объем входных данных для следующей итерации цикла конвейерной обработки.

При этом большинство задач машинного зрения [Головастов, 2010] хорошо поддаются распараллеливанию при обработке данных. Например, каждая видеокамера передает один видеопоток, если таких камер несколько, то для повышения общего быстродействия весьма эффективно разделить конвейер на участки параллельной обработки, где это возможно, получив прирост производительности.

Механизм параллельно-конвейерной обработки является признанным классическим методом повышения быстродействия систем обработки данных, и если структура данных и алгоритм позволяют распараллеливать задачу, то это почти всегда повышает эффективность такой обработки.

Так, гетерогенность, архитектурные решения и программные механизмы взаимодействия модулей различной архитектуры позволяют эффективно применять ВГВП для гетерогенной параллельно-конвейерной обработки данных [Баранов и др., 2017].



Рассмотрим возможности ВГВП для организации параллельно-конвейерной обработки данных на примере системы обработки видео высокого разрешения в режиме реального времени.

Постановку задачи можно кратко сформулировать следующим образом: требуется в режиме реального времени принять данные от четырех камер высокого разрешения, провести предварительную обработку, передать данные на отдельный обработчик для отработки прикладных алгоритмов компьютерного зрения с дальнейшей передачей результата для принятия решения центральным процессором.

Исходя из постановки данной задачи был сконфигурирован аппаратный состав базового вычислительного блока – гетерогенного вычислителя на базе ВГВП – табл. 1, а дополнительные аппаратные средства представлены в табл. 2.

Таблица 1  
Table 1

**Аппаратный состав гетерогенного вычислителя обработки видео высокого разрешения на базе ВГВП**  
**Hardware structure of heterogeneous calculator processing high-definition video on the basis of VGVP**

Наименование	Описание	Внешний вид	Количество
CPC512	Модуль центрального процессора (может использоваться в микропроцессорах с архитектурой Эльбрус)		1 шт.
FPU500	Модуль ПЛИС		1 шт.



Окончание табл. 1




VIM556	Модуль графического процессора		4 шт.
KIC551	Модуль коммутации PCIe		1 шт.
KIC550	Модуль-носитель HDD-накопителя		1 шт.
MIC2003	Мезонинный модуль ввода		1 шт.

Таблица 2  
Table 2

**Дополнительные аппаратные средства  
Additional Hardware**

Наименование	Количество
Камеры full-hd	4 шт.
3G-SDI-коннекторы	4 шт.
Мониторы	4 шт.

На рис. 1 представлена схема параллельно-конвейерной обработки данных на базе ВГВП.



Рис. 1. Параллельно-конвейерная обработка данных на примере системы обработки видео высокого разрешения в режиме реального времени, построенной на базе ВГВП  
 Fig. 1. The parallel-pipelined data processing system as an example of processing high definition video in real time, based on the constructed VGVP

В статье рассмотрены этапы работы конвейера на конкретном примере.

Для ввода данных в вычислительный контур сразу от нескольких камер по стандарту 3G-SDI используется мезонинный submodule M1C, смонтированный на вычислительный модуль FPU500, что позволяет, во-первых осуществить ввод данных через нестандартные интерфейсы, а во-вторых осуществить ввод «напрямую» (без транзита по общей транспортной шине PCIe) на модуль FPU500 для дальнейшей обработки.

Поступающие на модуль FPU500 кадры видеоизображения разрешением 1920x1080 в формате 3G-SDI, далее декодируются и сохраняются в памяти модуля в формате YUV420, организованной в виде кольцевого буфера емкостью 16 кадров для каждой камеры. При очередной записи кадра модуль генерирует прерывание на шине PCIe, по которому управляющая программа на модуле центрального процессора CPC512 выдает команду на копирование кадра из памяти FPU500 в память модуля графического процессора VIM556 по линиям шины PCIe. Один модуль FPU500 может одновременно обслуживать видеопотоки от 4-х видеокамер.

На модуле графического процессора VIM556 в режиме реального времени средствами CUDA и компонентами библиотеки OpenCV обрабатываются нужные прикладные алгоритмы: поиск лиц (рис. 2), детектирование движения (рис. 3), дополнительная фильтрация (рис. 4) [Жиляков и др., 2016; Черноморец и др., 2012]. Далее средствами библиотек OpenGL и XLib прошедший обработку на VIM556 кадр без передачи по PCIe в режиме реального времени отображается на подключенном к модулю VIM556 мониторе.



Рис. 2. Поиск лиц. Пример выведенного на монитор кадра из транслируемого видеопотока  
 Fig. 2. Search persons. Example outputted to the monitor frame of broadcast video

Пояснение 1: Поиск лиц в кадре производится на видеокарте с помощью объекта класса `cv::cuda::CascadeClassifier` библиотеки OpenCV. Функция поиска лиц в OpenCV – синхронная операция, занимающая порядка 20 мс, поэтому она запускается в отдельном потоке CPU, чтобы не замедлять отображение кадров. Обнаружив объект, программа выделит его местоположение в кадре белым прямоугольником и плавно выдвинет найденное изображение в левую часть экрана. Для снижения времени поиска кадр сжимается в 4 раза.



Рис. 3. Детектирование движения. Пример выведенного на монитор кадра из транслируемого видеопотока  
 Fig. 3. Motion Detection. Example outputted to the monitor frame of broadcast video

Пояснение 2: В основе процедуры поиска движения лежит объект класса `cv::cuda::BackgroundSubtractorMOG` библиотеки OpenCV, который работает с памятью видеокарты и вычисляет “опорное” фоновое изображение по последним полученным N кадрам. Вычитая фон из каждого нового кадра можно получить маску движения. Полученная маска разбивается примерно на 500 частей, в каждой из которых с помощью CUDA проводится фильтрация крупных движущихся участков. Используя найденные координаты движущихся объектов на оригинальное изображение накладываются белые квадратики.



Рис. 4. Фильтрация Собеля. Пример транслируемого видеопотока  
Fig. 4. Filter Sobel. An example of the broadcast video stream

Пояснения 3: Фильтрация Собеля выполняется с помощью объекта `cv::cuda::SobelFilter` библиотеки OpenCV.

Фильтр выделяет белым цветом границы областей различной яркости.

Процесс такой обработки идет по 4 параллельным гетерогенным конвейерам по количеству входных потоков данных – в данном примере задействованы 4 камеры. При этом основная нагрузка делегируется для выполнения средствами модуля на базе ПЛИС FPU500 и модулей графического процессора VIM556. Модуль центрального процессора CPC512 не задействован непосредственно в обработке данных, а выдает только управляющие команды, что существенно снижает его загрузку, высвобождая ресурсы для выполнения другого функционала.

Действительно, следует особо отметить, что одним из важных преимуществ ВГВП является поддержка режима «каждый с каждым» (peer-to-peer/P2P) при межмодульном взаимодействии по высокоскоростной шине PCIe. Это позволяет осуществлять пересылку данных от одного вычислительного модуля другому без участия центрального процессора.

В данном примере механизмы прямого межмодульного взаимодействия в режиме «каждый с каждым» позволяют высвободить ресурсы центрального процессора и снизить нагрузку на основной транспортный интерконнект по шине PCIe, что на практике позволяет минимизировать время обработки кадра по конвейеру.

Важным параметром ВГВП при разработке является производительность.

К основным характеристикам производительности конвейера можно отнести следующие параметры:

- конвейерная задержка
- пропускная способность
- уровень загрузки ЦП.

В статье рассмотрены полученные экспериментально значения этих параметров на базе представленной системы.

### 1. Оценка конвейерной задержки

В таблице 3 показаны длительности основных этапов цикла обработки кадра как вместе, так и без механизма “каждый с каждым”. Из приведенных данных видно, что реализованный механизм ВГВП межмодульного взаимодействия позволяет значительно сократить величину конвейерной задержки. На самом деле выигрыш от применяемого механизма «каждый с каждым»



еще более значителен, так как приведенные в таблице данные для режима “без PCIeP2P” не учитывают дополнительные временные затраты на пробуждение нити на CPU.

Таблица 3  
Table 3

**Длительность основных этапов цикла обработки кадра**  
**Duration of the main stages of the frame processing cycle**

Отображение и сжатие кадра с PCIeP2P	Передача кадра от FPU500 к VIM556	12 мс	16 мс
	Конвейер видеокодека NVIDIA	4 мс	
Отображение и сжатие кадра без PCIeP2P	Передача кадра от FPU500 к VIM556	12 мс	28 мс
	Передача кадра от CPC512 к VIM556	12 мс	
	Конвейер видеокодека NVIDIA	4 мс	

**2. Оценка пропускной способности**

В представленном примере модуль FPU500 готовит кадры объемом 3110400 байт для VIM556 от нескольких камер, например, 2-х камер, по 30 кадров в секунду. Общий объем видеоданных, поступающих в систему по PCI-Express, составляет 178 MB/s. На каждую видеокарту поступает половина от указанного объема. С каждой из 2-х видеокарт сжатые кадры отправляются на CPU в объеме 1 MB/s (таблица 4).

Таблица 4  
Table 4

**Объем видео данных**  
**The amount of video data**

Модуль	Входящий поток данных, MB/s	Исходящий поток данных, MB/s
FPU500		178
VIM556 N1	89	
VIM556 N2	89	
CPC512	2	

Для сравнения в таблице 5 приведены объемы потоков данных при работе стенда без механизма “каждый с каждым”.

Таблица 5  
Table 5

**Объемы потоков данных**  
**Volumes of data streams**

Модуль	Входящий поток данных, MB/s	Исходящий поток данных, MB/s
FPU500		178
VIM556 N1	89	
VIM556 N2	89	
CPC512	180	178

**3. Загрузка центрального процессора**

В задачи центрального процессора входят выдача управляющих команд модулям на прием/передачу данных, управление кодеком NVIDIA при сжатии видео в формат MPEG4 на видеокarte, управление выводом изображения на мониторы видеокарт.

Результаты оценки загрузки ЦП в различных режимах проведены с помощью приложения htop и показаны в таблице 6.

Таблица 6  
Table 6

**Результаты загрузки ЦП в различных режимах**  
**Results of CPU usage in different modes**

Режим работы стенда	Загрузка процессорной платы CPC512
Трансляция и сжатие видео от 1-й видеокамеры	Одно из 4-х ядер загружено на 36%
Трансляция и сжатие видео от 2-х видеокамер	Одно из 4-х ядер загружено на 50%
Трансляция, поиск лиц и сжатие видео от 2-х видеокамер	Одно из 4-х ядер загружено на 100%

Показано, что основное преимущество организации такой параллельно-конвейерной обработки в гетерогенной среде заключается в том, что:



во-первых, каждый вычислитель задействован на своем участке конвейера, где он обрабатывает те данные, для которых его архитектура оптимальна

во-вторых, организация междомодульного взаимодействия по принципу каждый с каждым, позволяет минимизировать конвейерную задержку – задержку при отработке одного полного цикла конвейера в момент времени.

в-третьих, позволяет разгрузить основной транспортный интерконнект

в-четвертых, позволяет существенно снизить нагрузку на центральный процессор и сэкономить его ресурсы для других задач.

Существенное развитие математического аппарата, методов и алгоритмов, применяемых в теории компьютерного зрения, все чаще находят практическое применение в различных прикладных областях раздела компьютерного зрения – машинного зрения, в том числе в системах реального времени. Как правило, задачи машинного зрения достаточно ресурсоемки, поэтому одной из важных задач эффективного практического применения этих теоретических результатов компьютерного зрения является поиск путей минимизации потребляемых вычислительных ресурсов при достижении требуемого быстродействия работы системы. Благодаря архитектурным возможностям ВГВП представляется возможным достигать оптимального результата при решении задач компьютерного зрения.

### Заключение

Показано, что реализация разработанных методов обработки изображений допускает распараллеливание вычислений, что позволяет использовать многопроцессорные вычислительные структуры.

### Список литературы

#### References

Галаган П.В., Тумакин Д.А., 2016. Высокопроизводительная гетерогенная вычислительная платформа для построения встраиваемых систем. Вопросы радиоэлектроники. 10: 21-31.

Galagan P.V., Tumakin D.A., 2016. High-performance heterogeneous computing platform for building embedded systems. *Voprosy radioelektroniki [Electronic Engineering]* 10: 21-31.

Жиляков Е.Г., Черноморец А.А., Болгова Е.В., 2016. О методе субполосной оптимальной интерполяции. Научные ведомости БелГУ. Сер. Экономика. Информатика. 2(223): 81-87.

Zhilyakov E.G., Chernomorets A.A., Bolgova E.V., 2016. Method subband optimal interpolation. *Nauchnye vedomosti BelGU. Ekonomika. Informatika. [Belgorod State University Scientific Bulletin. Economics Information technologies]*. 2(223): 81-87. (in Russian)

Жиляков Е.Г., Черноморец А.А., Болгова Е.В., Голошاپова В.А., 2016. О методе оптимальной субполосной фильтрации. Научный результат. Информационные технологии. 1(1): 58-64.

Zhilyakov E.G., Chernomorets A.A., Bolgova E.V., Goloschaporova V.A., 2016. On the method of optimal subband filtration. *Nauchnyj rezul'tat. Informacionnye tehnologii [Research result. Information Technology]* 1(1): 58-64. (in Russian)

Черноморец А.А., Лысенко И.В., Болгова Е.В., 2012. Компьютерная реализация алгоритма взвешенной оптимальной фильтрации изображений. Вопросы радиоэлектроники. 1: 103-111.

Chernomorets A.A., Lysenko I.V., Bolgova E.V., 2012. Computer implementation of algorithm for weighed optimal image filtration. *Voprosy radioelektroniki [Electronic Engineering]* 1: 103-111. (in Russian)

Головастов А., 2010. Машинное зрение и цифровая обработка изображений. Современные технологии автоматизации. 4: 8-18.

Golovastov A., 2010. Machine vision and digital image processing. *Sovremennye tehnologii avtomatizacii [Modern automation technology]* 4: 8-18. (in Russian)

Баранов Л.Д., Сорокин С.А., Галаган П.В., Чудинов С.М., 2017. Методология проектирования и производства отечественной высокопроизводительной гетерогенной вычислительной платформы в рамках импортозамещения. Вопросы радиоэлектроники. 2: 14-21.

Baranov L.D., Sorokin S.A., Galagan P.V., Chudinov S.M., 2017. Methodology for the design and production of domestic high-performance heterogeneous computing platform under the import substitution. *Voprosy radioelektroniki [Electronic Engineering]*. 2: 14-21. (in Russian)