



В.В. Мокшин, Л.М. Шарнин

ПОИСК ИНФОРМАЦИИ В ВИДЕОПОТОКЕ С ИСПОЛЬЗОВАНИЕМ ТЕХНОЛОГИЙ ВЫСОКОПРОИЗВОДИТЕЛЬНЫХ ВЫЧИСЛЕНИЙ

(ФГБОУ ВПО «Казанский национальный исследовательский технический университет им. А.Н. Туполева – КАИ»)

В современном мире накапливается большое количество видеoinформации. В настоящее время используется большое количество камер видеонаблюдения для различных целей. Одно из активно развивающихся направлений являются навигационные системы для автомобильной техники. Благодаря этим системам можно следить за маршрутом движения транспортных средств. Это касается тех же самых камер фиксации скоростного режима на дорогах. Имея большое количество камер фиксации и идентификации автомобиля, возникают вопросы об обнаружении местоположения и передвижения авто из распределенной видеoinформации с камер фиксации скоростного режима автомобилей, покрывающих город или регион. Также актуальным является анализ распределенной видеoinформации для метрополитена, для логистических служб и т.д.

В связи с этим, актуальным является разработка информационно-навигационной системы, которая могла бы позволить анализировать распределенную видеoinформацию и формировать пути движения транспортных средств в условиях зашумленности поступающей информации.

В работе проводится разработка научно-обоснованных методов обнаружения объектов на изображениях видеопоследовательности, математического описания, методики проектирования, экспериментального исследования и применения в системах сопровождения движущихся объектов с улучшенными метрологическими и эксплуатационными характеристиками, функционирующих в реальном масштабе времени с использованием средств высокопроизводительных вычислений.

В рамках данной работы получены следующие результаты:

- Разработан метод формирования нелинейной регрессионной модели для исследования многопараметрических систем, отличающийся модификацией полинома Колмогорова-Габора с возможностью использования элементарных функций от входных признаков и результатов многофакторного анализа.
- Разработан численный метод отбора значимых признаков на основе предложенного параллельного генетического алгоритма, формирующего конечное множество эволюционных путей для отбора признаков.
- Разработан метод формирования структуры регрессионных зависимостей, отличающегося алгоритмом построения характеристических матриц структуры на основе параллельной обработки групп признаков.



- Разработан алгоритм определения оптимальных значений результативных показателей на основе полученной нелинейной регрессионной модели. уменьшением k - мерного пространства целей до двумерного с использованием нечеткой логики и генетического моделирования.
- Разработан комплекс методик и программ, реализующий предложенные методы и алгоритмы.
- Разработан алгоритм обработки данных с использованием расширенного фильтра Калмана при рассмотрении вопроса комплексирования инерциальной навигационной системы (ИНС) с системой глобального местоположения для повышения точности позиционирования подвижного аппарата в пространстве.

Практическая ценность полученных научных результатов состоит в том, что разработана методика моделирования многопараметрической системы. Разработанные алгоритмы позволяют тестировать разработанный метод на требуемое количество параллельных эволюционных путей, определять оптимальные параметры генетических алгоритмов отбора значимых признаков. Расширяется возможность определения оптимальных значений результативных показателей нелинейной регрессионной модели многопараметрической системы. Модели, алгоритмы и комплекс программ является инструментальным средством для моделирования многопараметрических систем и исследования свойств нелинейных регрессионных моделей с использованием генетического моделирования, нечеткой логики и параллельных вычислений.

Одной из проблем в системах обнаружения, идентификации и управления подвижных объектов является достижение заданной точности обработки меняющихся изображений (видеоизображений) в реальном масштабе времени. Для решения данной проблемы можно использовать нейросетевые методы с применением вейвлет-преобразования. При этом перспективными являются процедуры параллельной обработки изображений и использование генетических алгоритмов для обучения нейросетевой системы. Таким образом, актуальными являются задачи поиска оптимальных аппаратно-программных вычислительных структур для параллельной обработки изображений на основе вейвлетов, нейронных сетей и генетических алгоритмов.

Для решения задачи обработки распределенной видеoinформации с использованием параллельных и распределенных вычислений является применение GRID-технологий. GRID-среда S образована множеством узлов $gs_i : S = \{gs_1, gs_2, \dots, gs_f\}$, где gs_1, gs_2, \dots, gs_f — ресурсы, f — число ресурсов в GRID-среде S . Каждый ресурс gs_i является совокупностью вычислительных узлов, управляемых локальным планировщиком распределения обработки и менеджером управления ресурсами.

Обработка видеофайла представляет собой совокупность распределенно выполняемых *заданий* (tasks) по обработке видеoinформации, объединенных в один *план* (job). Задание z_i является неделимым блоком операций, выполняемых на одном вычислительном узле. План J — это множество заданий, которые



должны быть выполнены для получения результата обработки:

$$J = \{z_1, z_2, \dots, z_N\}.$$

Выполнение плана в GRID-среде означает, что любой узел gs_i при обработке плана J может использовать ресурсы любого $gs_k \in S, k = 1, \dots, N$.

Таким образом, план отождествляет один видеофайл, а для формирования заданий выбран метод, в котором минимальной единицей обработки (одним заданием) является независимо сжатая группа изображений (GOP — Group of Pictures). Этот метод позволяет максимально по сравнению с остальными существующими методами, сократить объем передаваемых данных, увеличением вычислительной нагрузки на конечные узлы. Его использование обусловлено тем, что наиболее узким местом распределенной обработки видеофайлов является время передачи данных ввиду их большого объема.

Выбор правильных признаков играет критическую роль в слежении. Вообще, самая желательная собственность визуального признака - своя уникальность так, чтобы объекты могли быть легко отличенными в пространстве признаков. Согласно уровню признаки можно разделить на признаки низкого уровня (цвет, градиент), среднего уровня (край, угол, область) и высокого уровня (объект). Вообще, много алгоритмов слежения используют комбинацию этих признаков. Среди самых распространенных визуальных признаков можно встречаются: цвет, контуры, оптический поток и текстура. Для отбора значимых признаков объекта используются GRID-технологии. Проводится сравнение с другими методами отбора значимых признаков.

Число локальных узлов в сайте представляется как

$$GN = \sum_{i=1}^{N_{ad}} \sum_{j=1}^{N_i} G_{ij} \quad (1)$$

где N_{ep} – число групп узлов; N_i – количество узлов в i -й группе.

Для вновь добавленных в систему внешних узлов, первое обработанное задание присылается из расчета $GP = 1$ и становится тестовым. В дальнейшем производительность определяется исходя из полученного значения времени работы тестового узла.

Из предложенного принципа определения производительности узлов следует, что время обработки определяется как

$$T_{\text{выч.}} = TN_n * GP_{\text{тест.}} * t_{\text{тест.}} + TN * t_{z0} \quad (2)$$

где $GP_{\text{тест.}}$ – производительность тестового узла локального вычислительного сайта; $t_{\text{тест.}}$ – время обработки одного задания тестовым узлом; TN – число заданий в плане; t_{z0} – время задержки при обработке на вычислительном узле; TN_n – число задач, выполняемых группой узлов с производительностью $GP_{\text{тест.}}$, которое вычисляется как



$$TN_n = TN / \sum_{i=1}^N GN_i * \frac{t_{mest\ обр.} + t_{mest\ пер.}}{t_{j\ обр.} + t_{i\ пер.}} \quad (3)$$

где N – число групп узлов; GN_i – число узлов в i -й группе; $t_{mest\ обр.}$ – время обработки одного задания тестовым узлом, а $t_{j\ обр.}$ – время обработки i -м узлом; $t_{mest\ пер.}$ – время передачи одного задания тестовым узлом, а $t_{j\ пер.}$ – время передачи i -м узлом. При этом:

$$t_{обр.} = GP * tt \quad t_{mest\ пер.} = JV * GN / U + TN * t_{зн} \quad (4)$$

где U – скорость канала передачи данных; JV – объем данных видеофайла; GN – число узлов; $t_{зн}$ – время задержки при передаче данных; GP – производительность узла; tt – время обработки одного задания;

Время передачи данных вычисляется согласно выражению

$$T_{ид.} = 2 * JV * GN / U + TN * t_{гр.} + t_{пää.} \quad (5)$$

где $t_{сдвига}$ – время сдвига окончания обработки, определяемое числом задержек.

Таким образом, время обработки видеоинформации в GRID-среде описывается математической моделью:

$$t_j = TN_n * GP_{тест} * t_{mest} + TN * t_{зо.} + \frac{2 * JV * GN}{U} + TN + t_{зн.} + t_{сдв.} \quad (6)$$

Таким образом, один видеофайл может быть разбит на различное число заданий. Поэтому план содержит JK кадров с общим объемом данных JV . Задания представляют собой отрезок TK кадров, содержащих TV объем данных. При этом результат TK / K – целое число, где K – количество кадров в одном GOP. Отсюда

$$TK = JK / TN \quad TV = JV / TN \quad (7)$$

Таким образом, TN определяется как

$$TN = JK / NK * K \quad (8)$$

где NK – число GOP в одном задании.

Предложенный подход к анализу распределенных видеоинформации позволяет по сравнению с SIFT-дескриптором увеличить быстродействие этапа построения дескрипторов в 40 раз и уменьшить их размерность от 128 до 60. В итоге увеличивается быстродействие сопоставления на 25%, а малая размерность пространственного дескриптора позволяет уменьшить объем требуемой памяти для их сохранения и время их передачи. Разрабатываемая система позволяет использовать распределенную видеоинформацию для формирования траектории движения мобильных объектов, а также слежение за ними.

Литература

1. Аун С., Шарнин Л.М. Дескриптор пространственного распределения ключевых точек для сопоставления изображений, КГТУ им. А.Н. Туполева, Июнь 2011 СС.
2. Ермаков А.В. Разработка и анализ метода повышения эффективности обработки видеоинформации с использованием GRID-вычислений / А.В. Ерма-



ков // Вестник Саратовского государственного технического университета, 2010. №51. – с. 184 – 188

3. Мокшин В.В. Параллельный генетический алгоритм отбора значимых факторов, влияющих на эволюцию сложной системы // Вестник КГТУ, 2009. – № 3. – с. 89 – 93

4. Мокшин В.В., Якимов И.М., Юльметьев Р.М., Мокшин А.В. Рекурсивно-регрессионная самоорганизация моделей анализа и контроля сложных систем // Нелинейный мир. М: 2009. – №1. – с. 48 – 63

5. Foster I. The Grid2: Blueprint for a New Computing Infrastructure, Morgan Kaufmann / Foster and C. Kesselman. Morgan Kaufmann, 2003.

6. Polychronopoulos C.D., Kuck D.J. Guided self-scheduling: A practical scheduling scheme for parallel supercomputers Текст. // IEEE Transactions on Computers. 2007. – том 36. – № 12. – с. 1425 – 1439