

Лекция 3. Производительность системы функциональных устройств.

1. Оценка реальной производительности ВС.

Любая ВС – совокупность функциональных устройств (ФУ). ФУ бывают двух типов:

Простое ФУ – если на нем никакая другая операция не может начаться, пока не кончится предыдущая (монопольное использование всего оборудования для выполнения операции).

Конвейерное ФУ – ФУ, которое может выполнять одновременно несколько элементарных операций в режиме конвейера (обычно это линейная цепочка простых элементарных ФУ, имеющих одинаковые времена срабатывания). Элементарные ФУ – **ступени конвейера**, их число – **длина конвейера**. Простое ФУ = конвейерное ФУ с длиной 1. Все ФУ выполняют одну или несколько операций, скорость их работы измеряется в операциях в секунду.

Предположение 1 – время выполнения конкретной операции на конкретном ФУ фиксировано, не равно 0 и не зависит от других ФУ.

Предположение 2 – любое ФУ не может одновременно выполнять операцию и сохранять результат предыдущего срабатывания – т.е. не имеет собственной памяти. Результат предыдущего срабатывания хранится в нем до начала следующей операции, а затем пропадает.

Предположение 3 – все ФУ работают по индивидуальным командам: команда + аргументы попадают на вход ФУ. При этом не происходит тупиковых ситуаций.

Предположение 4 – Если отрезок времени работы ФУ равен T , а длительность операции τ , то целое число операций Q , выполненных за время T , равно либо $[T/\tau]$, либо $[T/\tau]-1$. При больших T эти величины асимптотически совпадают.

Стоимость операции ФУ – время ее реализации на ФУ (время срабатывания ФУ).

Стоимость работы ФУ – время последовательной реализации всех операций на простых ФУ с аналогичными временами срабатывания.

Загруженность ФУ ($0 \leq Z \leq 1$) – отношение стоимости реально выполненной работы S_R за фиксированный промежуток времени T к максимально возможной стоимости S_M . Q – число выполненных ФУ операций за время T .

Утв. 1. $S_M = T$ для простого ФУ, $S_M = L * T$ для конвейерного ФУ с длиной конвейера L , $S_R = Q * \tau$.

Реальная производительность ВС (P_R) – количество операций, выполненных ВС в среднем за единицу времени.

Пиковая производительность ВС (P_M) – максимальное количество операций, которое может быть выполнено ВС за единицу времени при отсутствии связей между ее ФУ.

Утв. 2. $P_R = \sum_{k=1}^m Z_k P_{M,k}$, $P_M = \sum_{k=1}^m P_{M,k}$, где m – кол-во ФУ, $P_{M,k}$ и Z_k – их пиковые производительности и загруженности. Док-во:

Простое ФУ ($L=1$): $P_M=1/\tau$, $S_R=Q*\tau$, $S_M=T$, $Z=S_R/S_M=Q*\tau/T$, $P_R=Q/T=(Q*\tau/T)*(1/\tau)=Z*P_M$ – ч.т.д.
Конвейерное ФУ ($L>1$): $P_M=L/\tau$, $S_R=Q*\tau$, $S_M=L*T$, $Z=(Q*\tau)/(L*T)$, $P_R=Q/T=(Q*\tau)/(L*T)*(L/\tau)=Z*P_M$ – ч.т.д.

Аддитивность формул доказывает Утв. 2 для любого кол-ва устройств.

Для одного устройства: $P_R = Z * P_M \Rightarrow$ для повышения P_R надо увеличивать Z .

Для системы устройств: $Z = \sum_{k=1}^m \alpha_k Z_k$, $\alpha_k = P_{M,k} / P_M \geq 0$, $\sum_{k=1}^m \alpha_k = 1 \Rightarrow 0 \leq Z \leq 1$.

Вывод: для увеличения загруженности системы необходимо повышать загруженность каждого ФУ.

Пример: ВС имеет два устройства - сумматор и умножитель с одинаковой пиковой производительностью. Решаем задачу $C = A + B$. При обычной схеме решения имеем $P_R = 0.5 P_M$. Можно ли повысить реальную производительность? Да: $C = A + 1*B \Rightarrow P_R = P_M$ – но кому это нужно?

2. Ускорение и эффективность использования МВС.

Опр. 1. Ускорение - отношение $S_m = T_1/T_m$ ($0 \leq S_m \leq m$) времен выполнения одной задачи на системе из m и одного одинаковых процессоров (ФУ). **Эффективность** $E_m = S_m/m$ или $E_m = S_m/m*100\%$.

Это определение годится только для систем с одинаковыми процессорами (ФУ). На неоднородных ВС с различными ФУ **эффективность совпадает с загруженностью**, а ускорение определяется иначе:

Опр. 2. Ускорение на неоднородной ВС есть $S_m = P_R / \max_{1 \leq k \leq m} P_{M,k} = \sum_{k=1}^m Z_k P_{M,k} / \max_{1 \leq k \leq m} P_{M,k}$.

Утв. 3. В системе из m устройств с одинаковой пиковой производительностью ($P_{M,1} = \dots = P_{M,m}$):

$$1) Z = \frac{1}{m} \sum_{k=1}^m Z_k \quad 2) P_R = \sum_{k=1}^m P_{R,k} \quad 3) P_M = m P_{M,1} \quad 4) S_m = \sum_{k=1}^m Z_k \quad 5) \text{ если все ФУ простые } \Rightarrow S_m = T_1 / T_m.$$

Рассмотрим ВС из m простых ФУ. Пусть между ними установлены какие-то функциональные связи, которые не меняются со временем. Их можно отобразить в виде ориентированного мультиграфа: точки – ФУ, дуги – связи между ФУ (если результат с выхода одного ФУ передается сразу на вход другого). Назовем этот мультиграф **графом ВС**. Предположим: исходные данные введены в ВС мгновенно, результаты работы одного ФУ передаются другому без задержки. Исследуем **максимальную производительность** такой ВС.

Утв. 4. Если все ФУ простые, а граф ВС связный $\Rightarrow P_{R,\max} = m \cdot \min_{1 \leq k \leq m} P_{M,k}$.

Следствие 1: При выполнении условий Утв. 4:

- 1) асимптотически каждое ФУ выполняет одно и тоже число операций в секунду;
- 2) загруженность любого ФУ не превосходит загруженность самого непроизводительного ФУ;
- 3) если загруженность какого-либо ФУ = 1, то это самое непроизводительное ФУ;
- 4) загруженность ВС $Z \leq Z_{\max} = m \cdot \min_{1 \leq k \leq m} P_{M,k} / P_M$;
- 5) ускорение ВС $S_m \leq S_{m,\max}^{(tech)} = m \cdot \min_{1 \leq k \leq m} P_{M,k} / \max_{1 \leq k \leq m} P_{M,k}$.

Следствие 2 (1-ый Закон Амдала): Производительность ВС, состоящей из связанных ФУ, в общем случае определяется самым непроизводительным устройством.

Следствие 3: Если все ФУ простые, а граф ВС связный \Rightarrow асимптотическая производительность ВС будет максимальной, если все устройства имеют одинаковые пиковые производительности.

Смысл: Расписание подачи команд должно минимизировать простои устройств!

3. Связь аппаратных и программных ограничений.

Рассмотрим ВС из m простых универсальных ФУ. Пусть Q – число всех элементарных операций алгоритма, q – максимальное число элементарных операций в параллельных ветвях алгоритма (**высота параллельной формы алгоритма**), k – число параллельных ветвей (**ширина параллельной формы алгоритма**).

$$A = \{O_1, \dots, O_Q\} = \left| \begin{array}{c} O_{11} \\ \dots \\ O_{1Q_1} \end{array} \right| \dots \left| \begin{array}{c} O_{k1} \\ \dots \\ O_{kQ_k} \end{array} \right| \Rightarrow \left| \begin{array}{c} O_{01} \\ \dots \\ O_{0Q_0} \end{array} \right| \quad \begin{array}{l} Q_1, \dots, Q_k - \text{выполняем} \\ \text{независимо} \\ Q_0 - \text{выполнение} \\ \text{зависит} \\ \text{от } Q_1, \dots, Q_k \end{array}$$

последовательный алгоритм и его операции параллельная форма алгоритма

Утв. 5. Максимально возможное ускорение $S_m \leq S_{m,\max}^{(alg)} = Q/q$ при любом числе устройств m .

Док-во: из утв. 3-4) имеем $S_m = Z_1 + \dots + Z_m = Q_1 \cdot \tau/T + \dots + Q_m \cdot \tau/T = Q \cdot \tau/T$, $T \geq q \cdot \tau \Rightarrow S_m \leq Q/q$.

Следствие 1: Минимальное число ФУ ВС, при котором может быть достигнуто максимально возможное ускорение, равно ширине алгоритма, т.е. $m \geq k$.

Пусть Q_0 операций из Q выполняются последовательно и $\beta = Q_0/Q$ – **доля последовательных вычислений**.

Следствие 2 (2-й закон Амдала): Если ВС состоит из m одинаковых простых универсальных ФУ и при выполнении параллельной части алгоритма они все загружены полностью, то $S_{m,\max} = m / [m \cdot \beta + (1 - \beta)]$.

Док-во: из утв. 3-4) $S_m = Z_1 + \dots + Z_m$, и все последовательные операции выполняются на первом ФУ $\Rightarrow Z_1 = [\beta \cdot Q \cdot \tau + (1 - \beta) \cdot Q \cdot \tau / m] / T = 1$, $Z_k = [(1 - \beta) \cdot Q \cdot \tau / m] / T$ ($k > 1$) $\Rightarrow S_m = 1 + (m - 1) \cdot [(1 - \beta) \cdot Q \cdot \tau / m] / [\beta \cdot Q \cdot \tau + (1 - \beta) \cdot Q \cdot \tau / m] \Rightarrow S_m = 1 + (m - 1) \cdot (1 - \beta) / [m \cdot \beta + (1 - \beta)] = m / [m \cdot \beta + (1 - \beta)]$ – ч.т.д.

Следствие 3 (3-й закон Амдала): Если ВС состоит из простых одинаковых универсальных ФУ, то при любом режиме работы ее ускорение $\leq 1/\beta$.

Зам. 1: На МВС с большим числом процессоров эффективно решаются задачи, где $\beta = 0.01 - 0.001$.

Зам. 2: 3-й закон Амдала используется для прогнозирования ускорения.

Резюме: Из характеристик ВС получаем m и $S_{m,\max}^{(tech)}$, из свойств алгоритма k и $S_{k,\max}^{(alg)}$ и сравниваем.

Первичен в любом случае алгоритм, то есть используемое в реальных вычислениях $m \leq k$.