Tema 03: Paralelismo y Pipelining

Arquitectura de Computadoras

Ing. Nicolás Majorel Padilla (npadilla@herrera.unt.edu.ar)

http://microprocesadores.unt.edu.ar/arqcom/

Temas que veremos

- Fundamentos de Paralelismo y Pipelining.
- Problemas reales
  - Cuellos de Botella
  - Organización de las tareas. Precedencia.
  - Colisiones. Riesgos.
- Medidas de Performance.
  - Aceleración y Eficiencia (rendimiento).
- Ejemplos de Aplicación
  - Sumador segmentado.
  - Organización de memoria (Interleaving)

Introducción

- **t = CI * CPI * T**

- ¿Cómo mejorar?
- ¿Y si queremos más? *¿Puede ser CPI < 1?*
- Pero… hay límites a la tecnología
  - Disipación de Calor, Velocidad de la luz.
- La clave: trabajar en cosas simultáneas.
  - Cerebro humano: mala tecnología, muy rápido. Mucho paralelismo.
- La mayoría de las máquinas actuales emplean:
  - Paralelismo, Pipelining y ambas (procesadores superescalares).
- Son temas **fundamentales** en Computación.

Paralelismo – Idea clave

- Agregar estaciones de trabajo.
- Hacer más trabajo en igual cantidad de tiempo.

- *¿Mejora latencia o productividad?*

Paralelismo – Ejemplo

- Para la fabricación de un determinado producto se requieren tres etapas:
  - 2 tareas independientes de 9 hs. cada una.
  - 5 tareas independientes de 3 hs. cada una.
  - 2 tareas independientes de 12 hs. cada una.
- Las tareas de cada etapa son independientes entre sí, pero las tareas de una etapa deben completarse antes de iniciar la etapa siguiente.
- Cada tarea es realizada por un trabajador.

- *Si tengo un solo trabajador, ¿cuánto demora en completar el trabajo?*
- *¿Y si tuviese dos trabajadores?*

Paralelismo – Métricas

- Factor de Aceleración
  - **A = t(serie) / t(paralelo)**
  - *¿Cuánto para el ejemplo?*

- Eficiencia (o rendimiento)
  - **Eficiencia = Trabajo realizado / Máximo trabajo posible**
  - *¿Cuánto para el ejemplo?*

Paralelismo – Ejemplo (cont.)

- Al aumentar la cantidad de trabajadores disminuye el tiempo total para hacer la tarea.
  - ¡Sigamos aumentando la cantidad de trabajadores!
  - Si pusiese diez trabajadores, *¿cuánto demoran en completar el trabajo?*
  - *¿Aceleración?*
  - *¿Rendimiento?*
- Es claro que el paralelismo tiene un límite
  - *¿Cómo podemos descubrirlo?*

Perfil de la Tarea

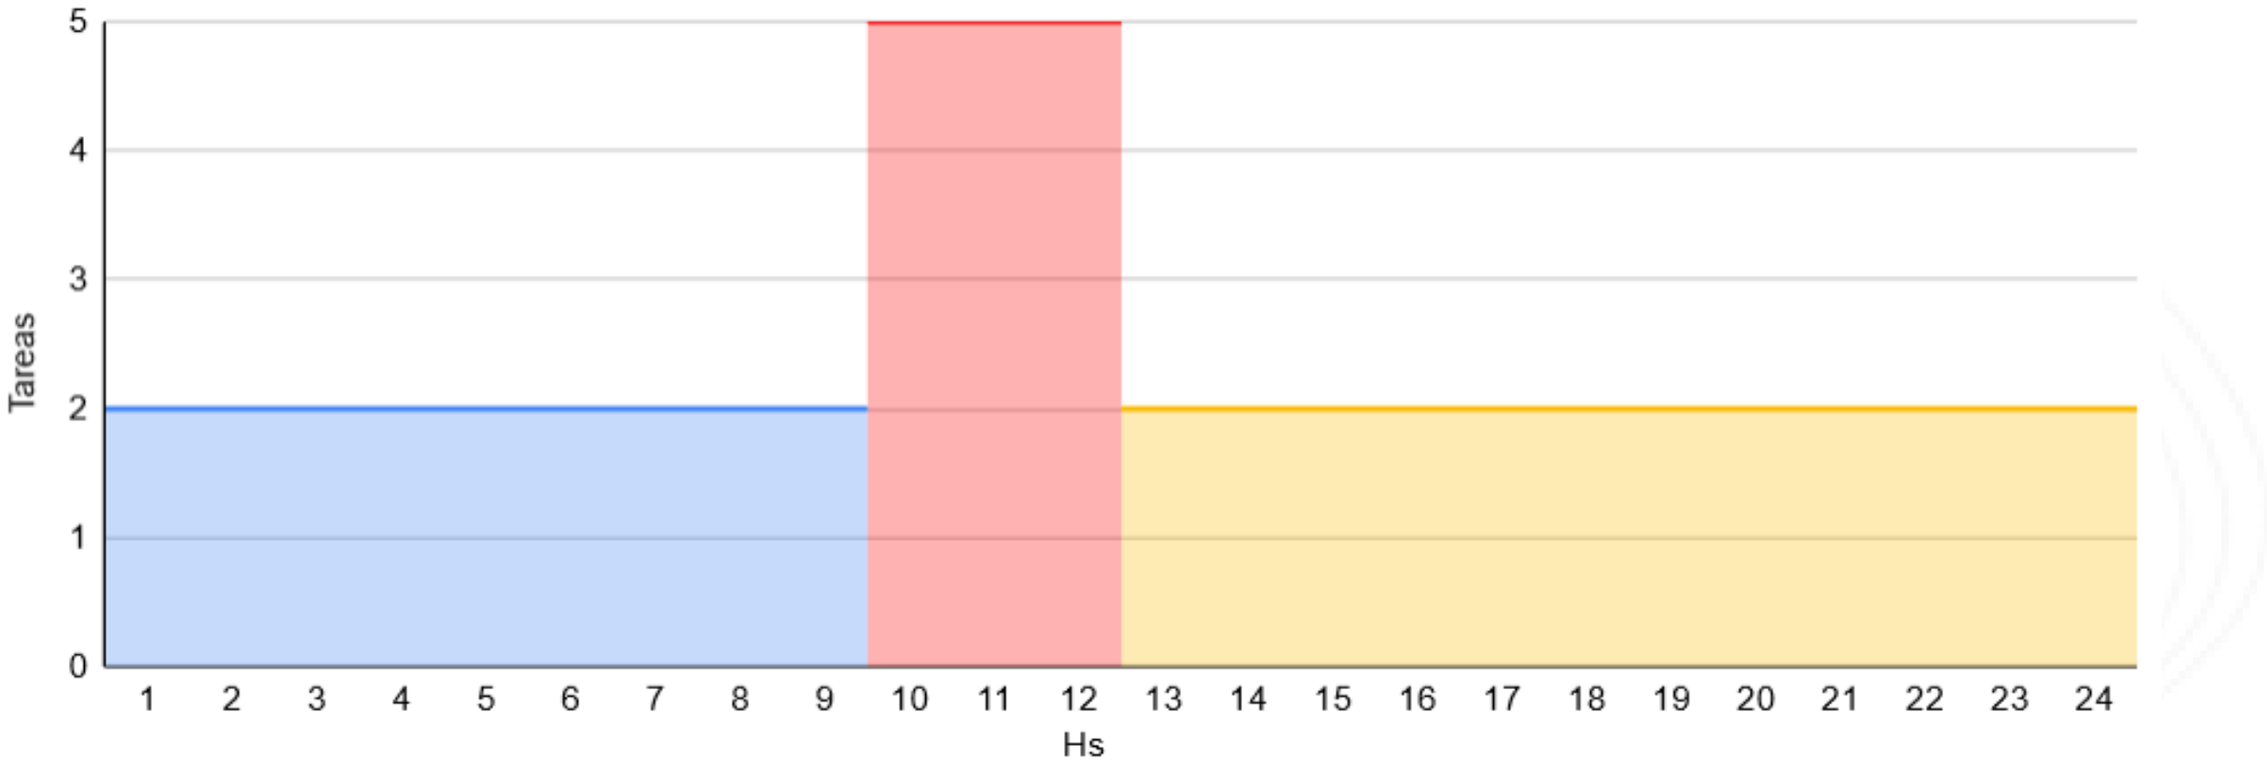

- Muestra **tareas *independientes*** que se pueden realizar **en función del tiempo**.
- Muestra dependencias (no se puede adelantar).
- Determina **duración mínima** de la tarea y cantidad máxima de estaciones de trabajo útiles (**grado de paralelismo**)
- Eficiencia = trabajo realizado/máximo posible (Área coloreada / Área total)

Perfil de la Tarea (limitado)

- El perfil anterior es el ideal. A veces es necesario construir un perfil con limitaciones.
- En nuestro ejemplo, suponiendo que tenemos como máximo 4 trabajadores disponibles en simultáneo, sería así:
  - La duración ya no es la mínima.
  - Podemos calcular la eficiencia de la misma manera.

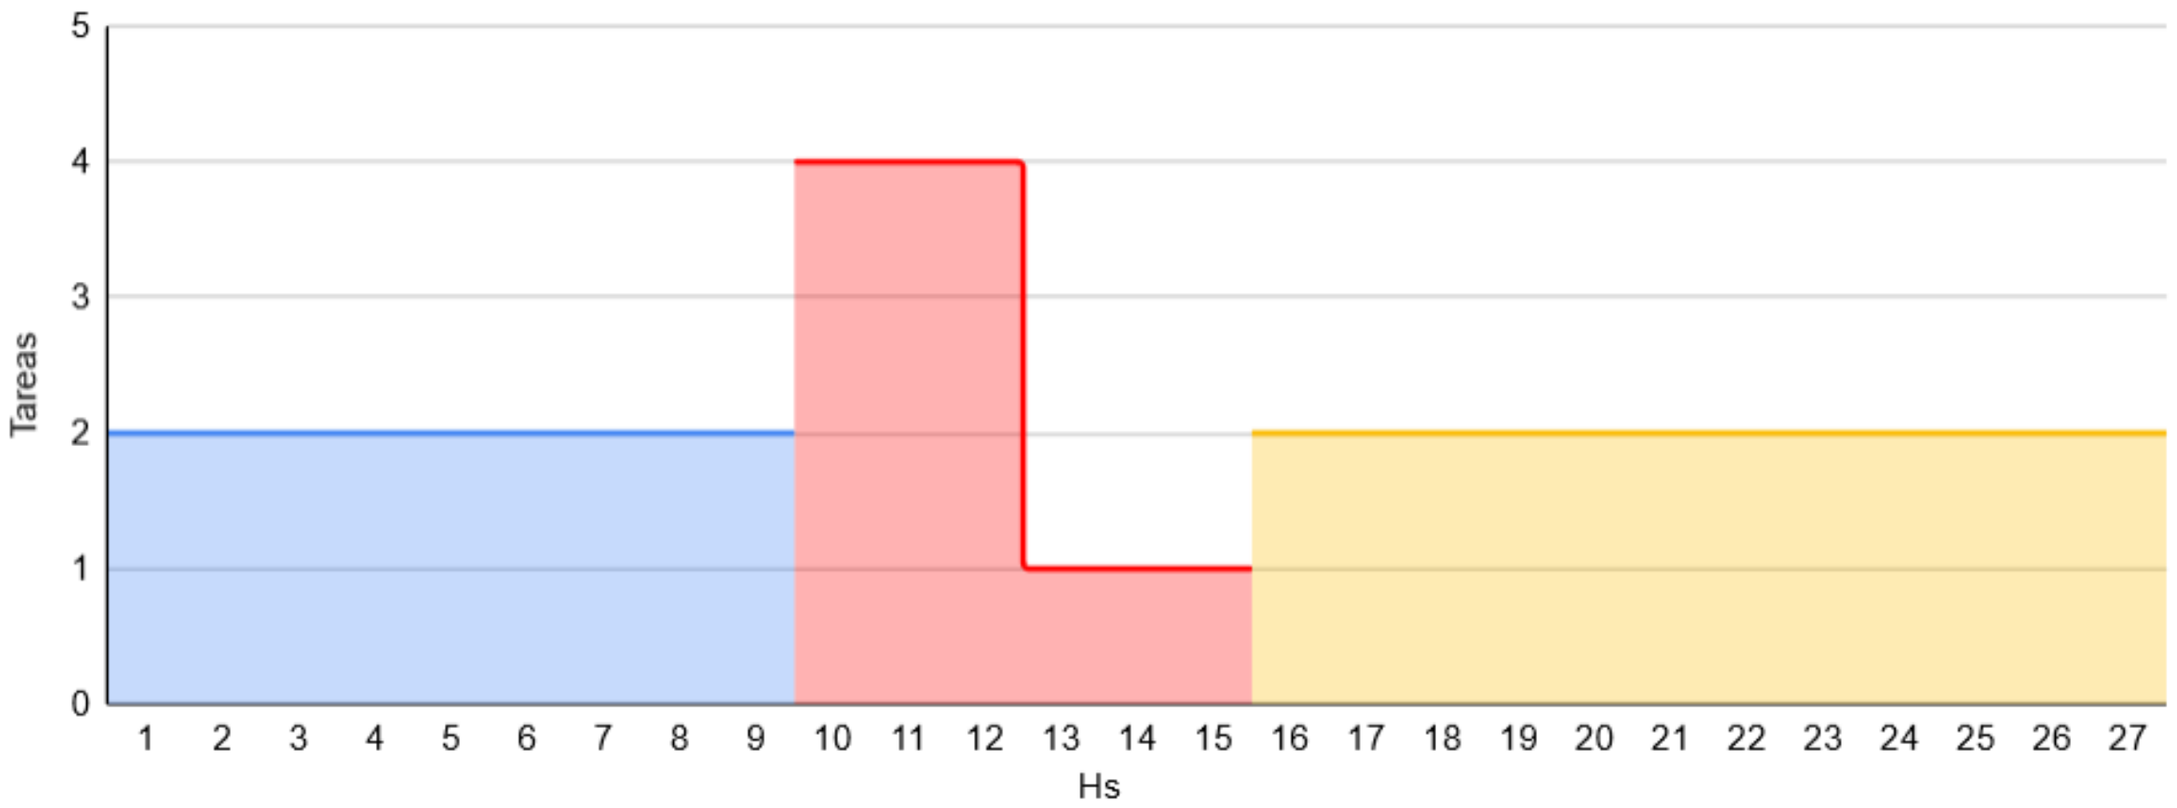

Pipelining – Idea clave

- Procesamiento en serie.
- Dividir la tarea en etapas secuenciales, e ir “solapando” su ejecución.
- Empezar a utilizar un recurso apenas esté disponible.
- *¿Mejora latencia o productividad?*

Pipelining – Ejemplo visto en SMM

- Ejemplo de una lavandería.
  - Juan, Manuel, Pedro y Miguel.
  - Cada uno tiene una carga de ropa
  - Los pasos son lavar, secar y doblar.
- Lavarropa demora 30 min.
- Secarropa demora 40 min.
- Planchado y embolsado demora 20 min.

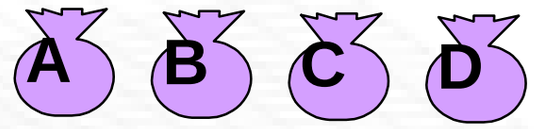

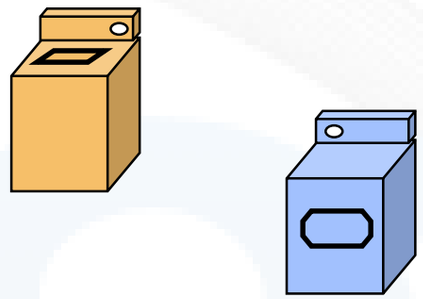

- *¿Cuánto tiempo demora en total cada carga?*
- *¿Y las cuatro cargas?*

Pipelining – Ejemplo visto en SMM

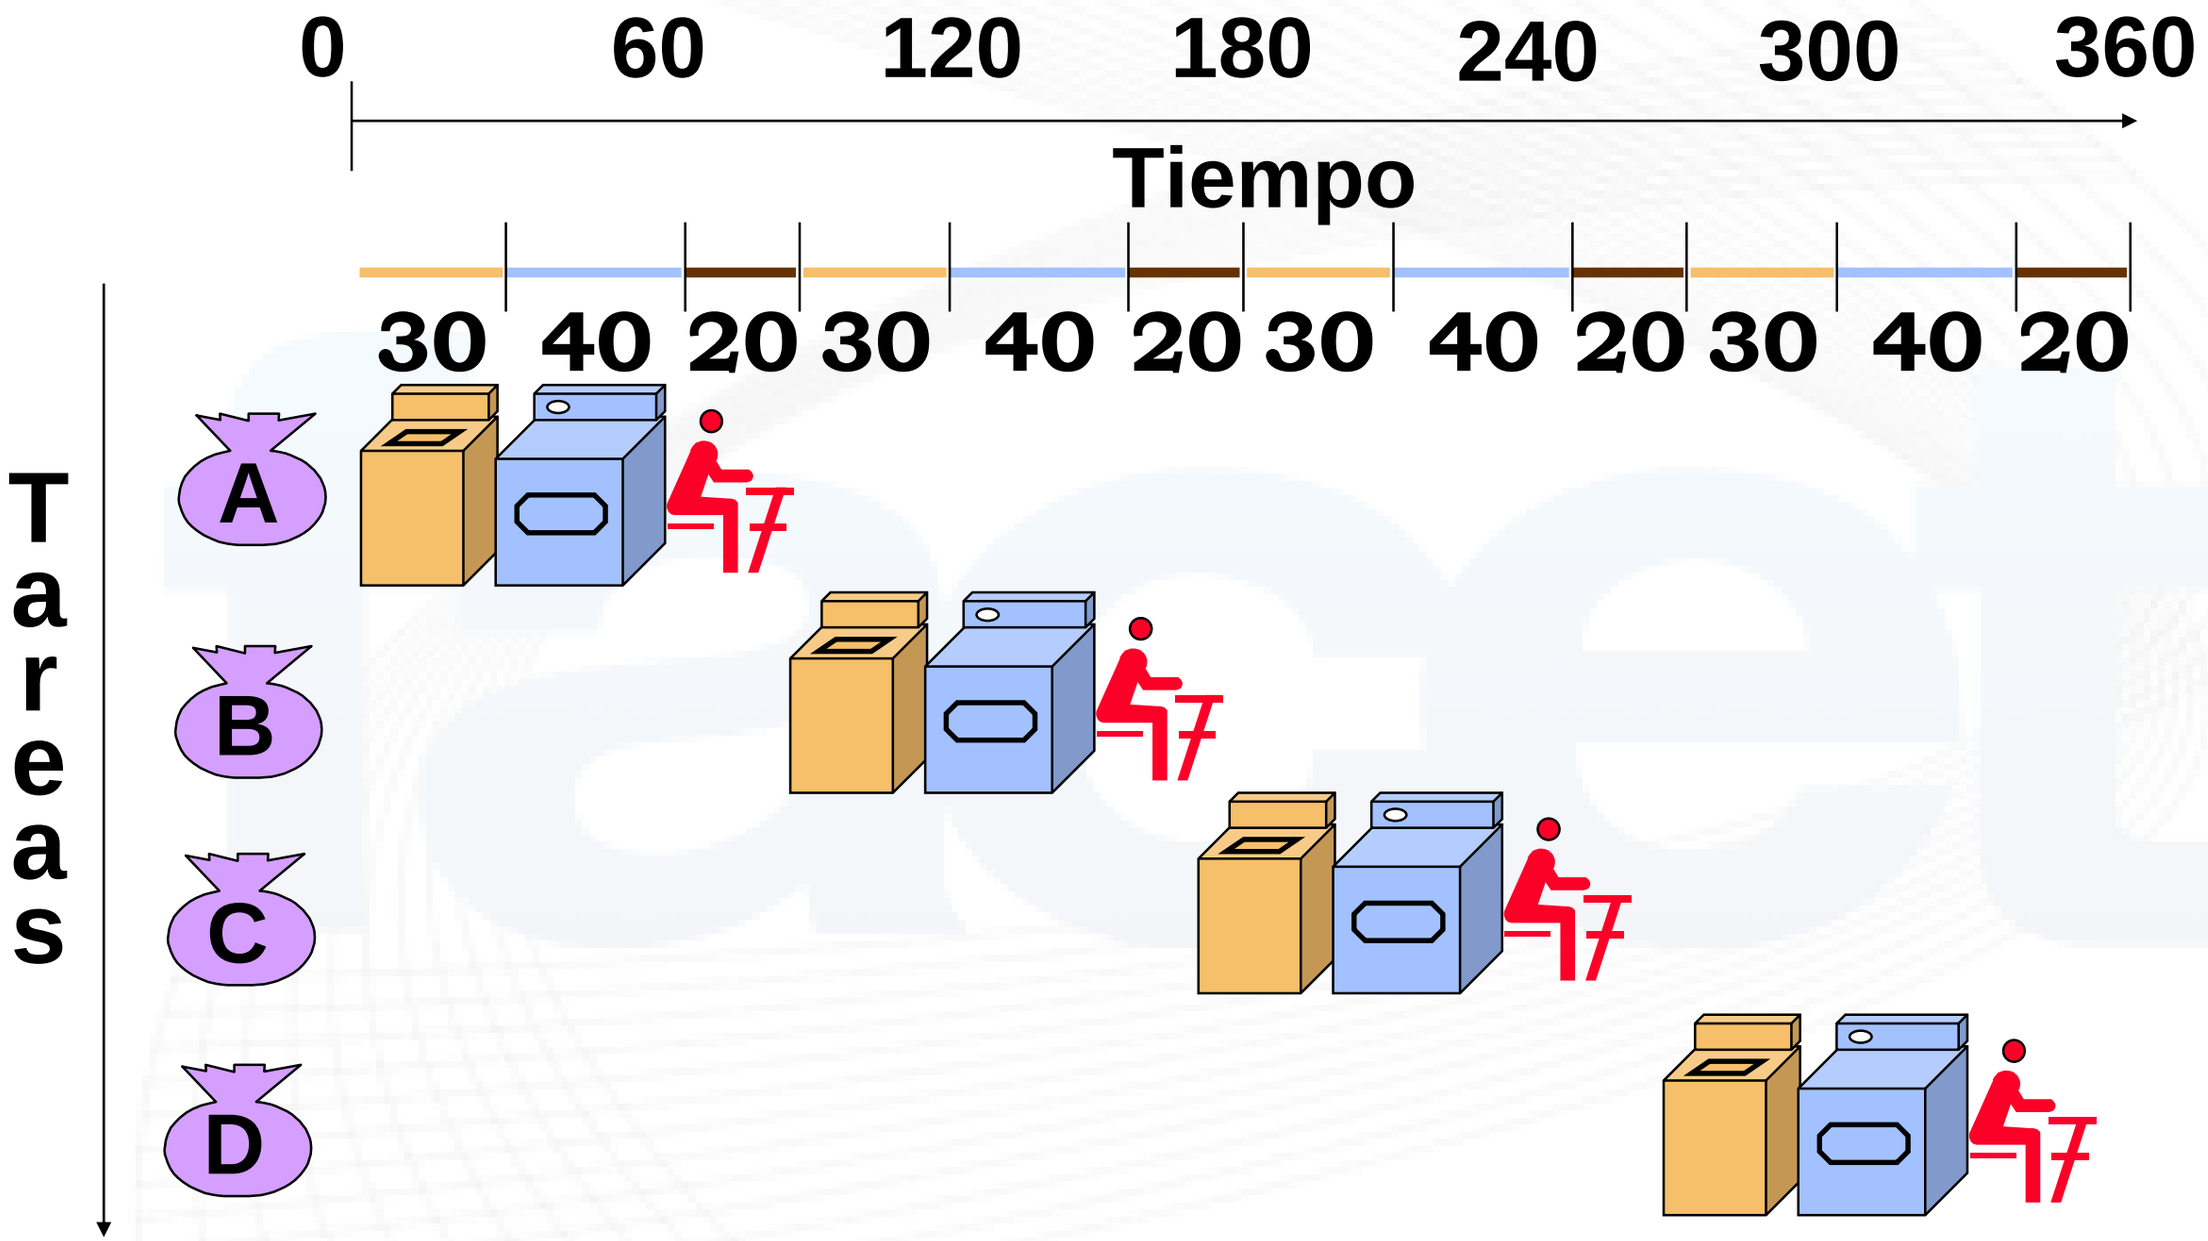

Lavado Secuencial demora 360 minutos para 4 cargas.

Pipelining – Ejemplo visto en SMM

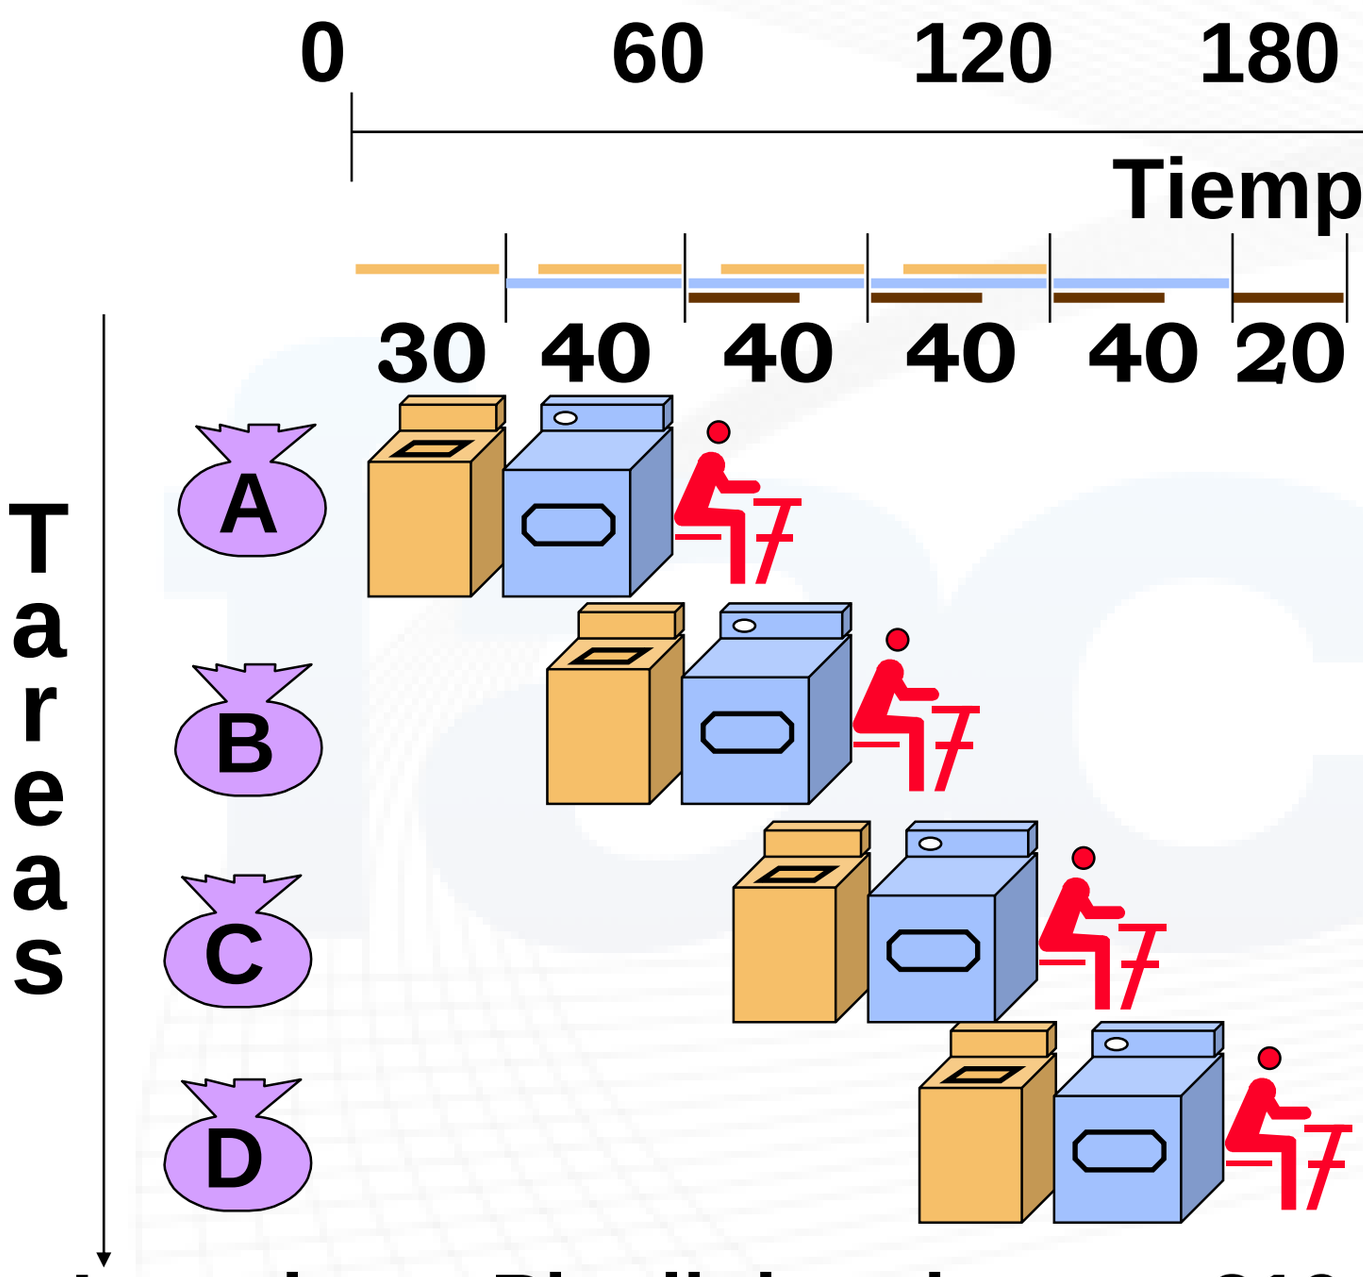

Los recursos (p.ej: lavarropas) empiezan a utilizarse apenas estén disponibles

Lavado en Pipelining demora 210 minutos para 4 cargas.

Pipelining – Métricas

- Productividad = Tasa de salida
  - Tareas completadas por unidad de tiempo.
- **Aceleración = t(serie) / t(pipe)**
- Latencia = tiempo total que demora una tarea
  - Desde que ingresa al pipeline hasta que sale.
- Eficiencia = Trabajo realizado / Máx posible.

- *¿Cuáles son estos valores para el ejemplo?*

Pipelining – Visualización

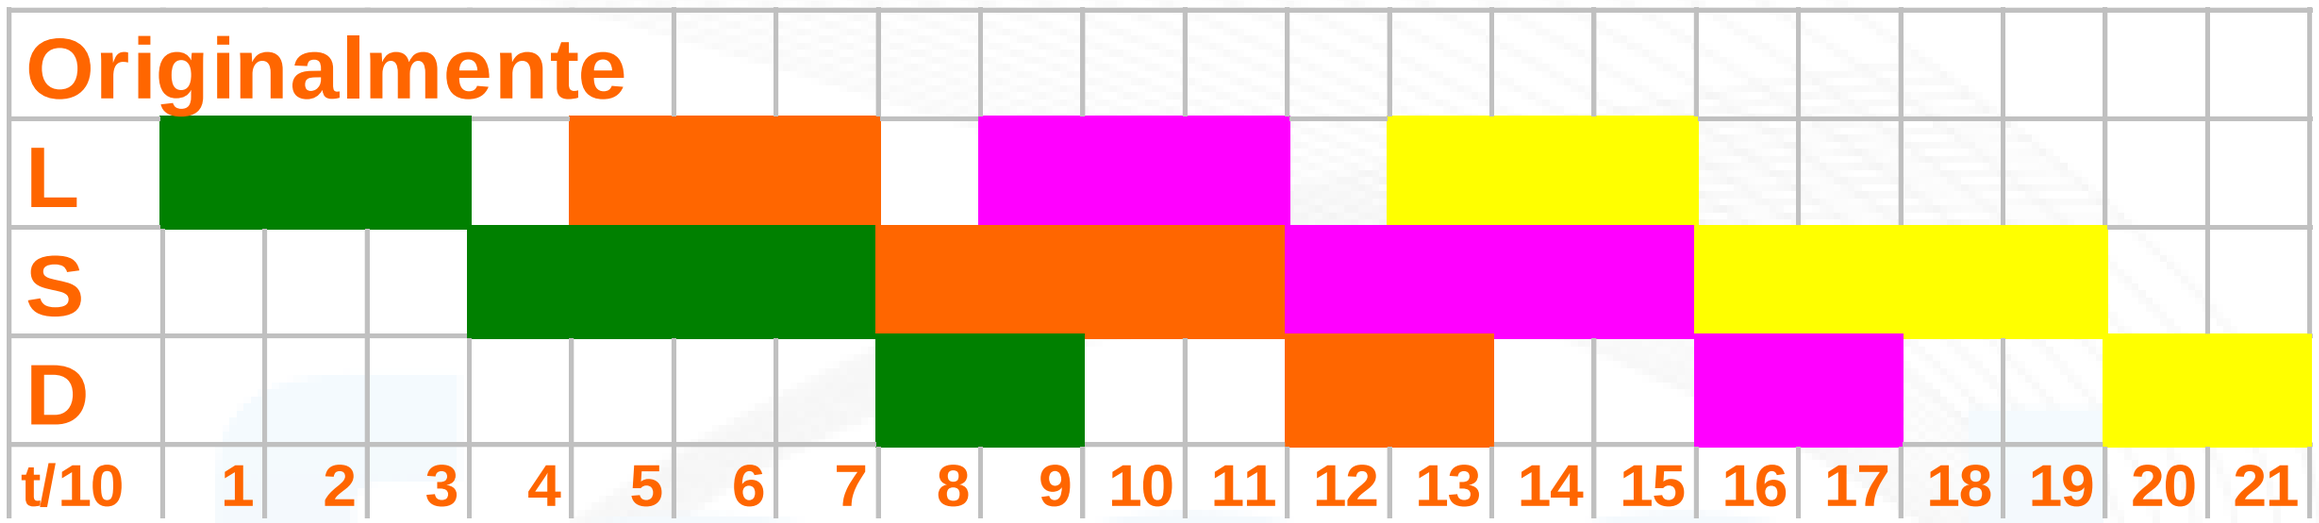

- En el eje vertical se ubican los distintos puestos de trabajo.
- En el eje horizontal, el tiempo.
- Las tareas se identifican con diferentes colores (o letras o números).
- Las tareas se van desplazando por los puestos de trabajo, **si es que el siguiente está disponible**.
  - Por ello es que hay una demora (“hueco”) al ingresar la segunda tarea.
- Se obtienen fácilmente: la duración total, la latencia de cada tarea, la productividad.
- Se puede calcular el rendimiento: área ocupada / área total.

Eficiencia vs Productividad

- *¿Cuál es la eficiencia de un único trabajador en un sistema serie?*
- Y si tengo **m** trabajadores en pipelining, con una eficiencia del 100%, ¿cuánto es la aceleración?
- Idealmente, en un pipeline se cumple que:
  - A = m * eficiencia
- Ojo, eficiencia del pipeline no es lo mismo que eficiencia de cada recurso.
  - ¿Cuál es la eficiencia en el uso del lavarropas?

Pipeline – Observaciones adicionales

- **Pipelining no mejora la latencia de una tarea particular**, pero sí la productividad de la carga total de trabajo.
- **La productividad está limitada por la etapa más lenta**.
- **En un mismo instante de tiempo, hay múltiples tareas ejecutándose simultáneamente** (¿paralelismo?).
- **Idealmente, la máxima aceleración posible es igual al número de etapas**.
- Si la duración de las etapas es desbalanceada, se reduce la aceleración (y el rendimiento).
- La aceleración también se reduce por tiempos de “llenado” y de “vaciado” del pipeline.

Pipeline ideal

- Posee m etapas equilibradas, de duración igual a T.
- Ejecuta una cantidad enorme de tareas idénticas, n → infinito.
  - Esto se denomina **estado de régimen**.
- Latencia = m*T
- Tiempo(serie) = n*m*T
- Tiempo(pipeline) = (m-1)*T+n*T
  - Una vez que se llena, sale una tarea cada T.
- Aceleración = m/[1+(m-1)/n] → m
- Productividad = 1/T
- Rendimiento = A / m = 100%

Pipelining – Problemas comunes

- No contar con suficientes tareas para entrar en estado de régimen.
  - Hay que considerar tiempos de llenado y vaciado.
- No contar con etapas de igual duración.
  - Produce cuellos de botella.
- Tener distintos tipos de tareas que utilicen distintas combinaciones de etapas.

Pipelining – Cuellos de botella

- En el ejemplo de la lavandería, una etapa era más lenta que las demás.
  - El secarropas demora 40 minutos.
  - En estado de régimen limita la productividad, disminuye el rendimiento y la aceleración.

- *¿Cómo podemos mejorarlo?*
  - Comprando un secarropas más rápido.
  - Comprando otro secarropas igual, y poniéndolos en serie.
    - Dividiendo la etapa de secado en dos etapas de 20 minutos.
  - Comprando otro secarropas igual y poniéndolos en paralelo.
    - Alternando el uso entre uno y otro.

Cuellos de botella – Solución serie

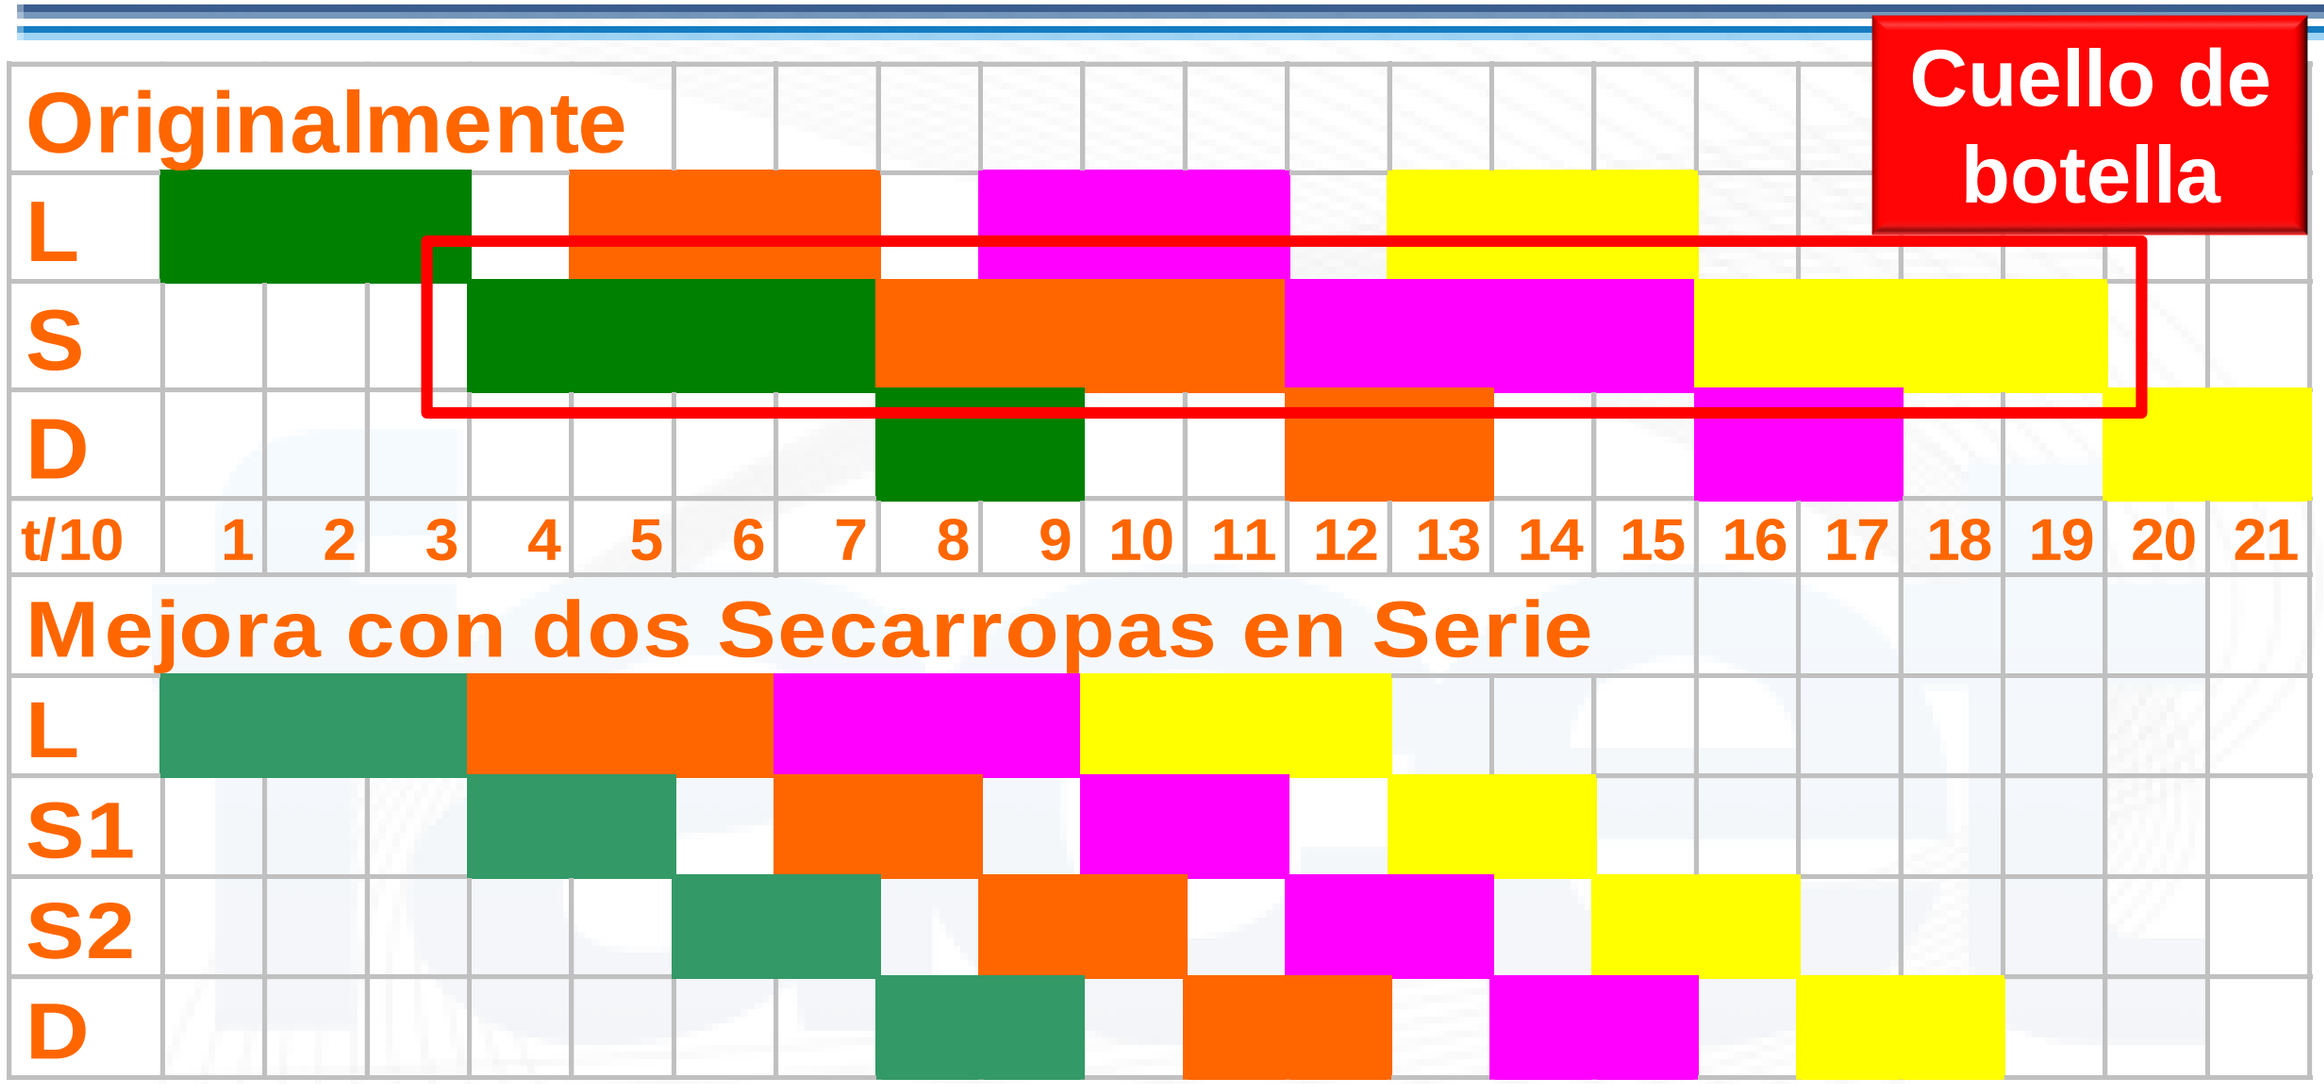

- *¿Nueva productividad?*
- ¡Hay un nuevo cuello de botella! *¿Alternativas?*

Cuellos de botella – Solución paralela

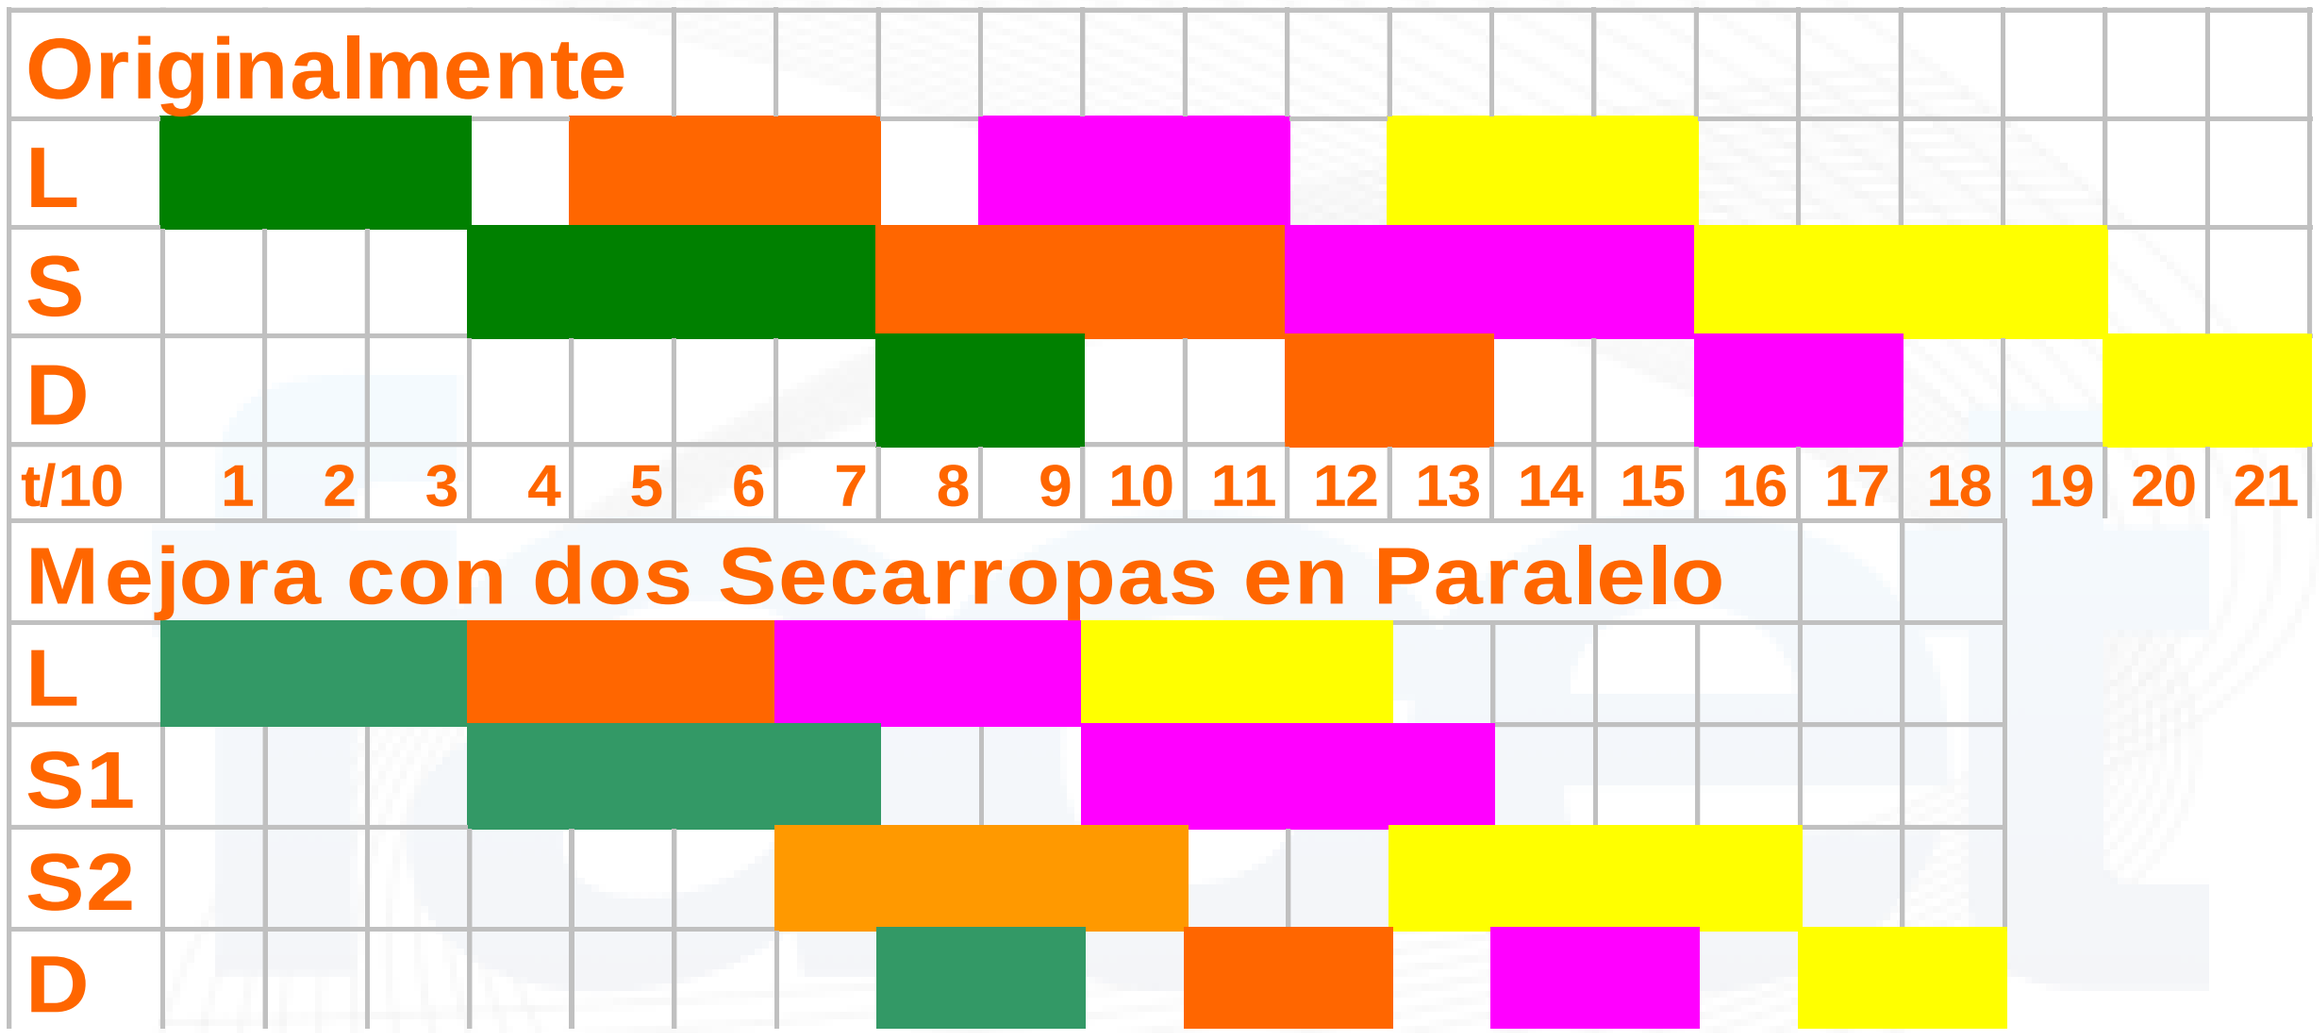

- *¿Nueva productividad?*
- Si se usa una alternativa en serie o en paralelo, depende exclusivamente de la tarea en sí.

Cuellos de botella – Solución extrema

- Al solucionar un cuello de botella, aparece otro. Repetimos la estrategia:

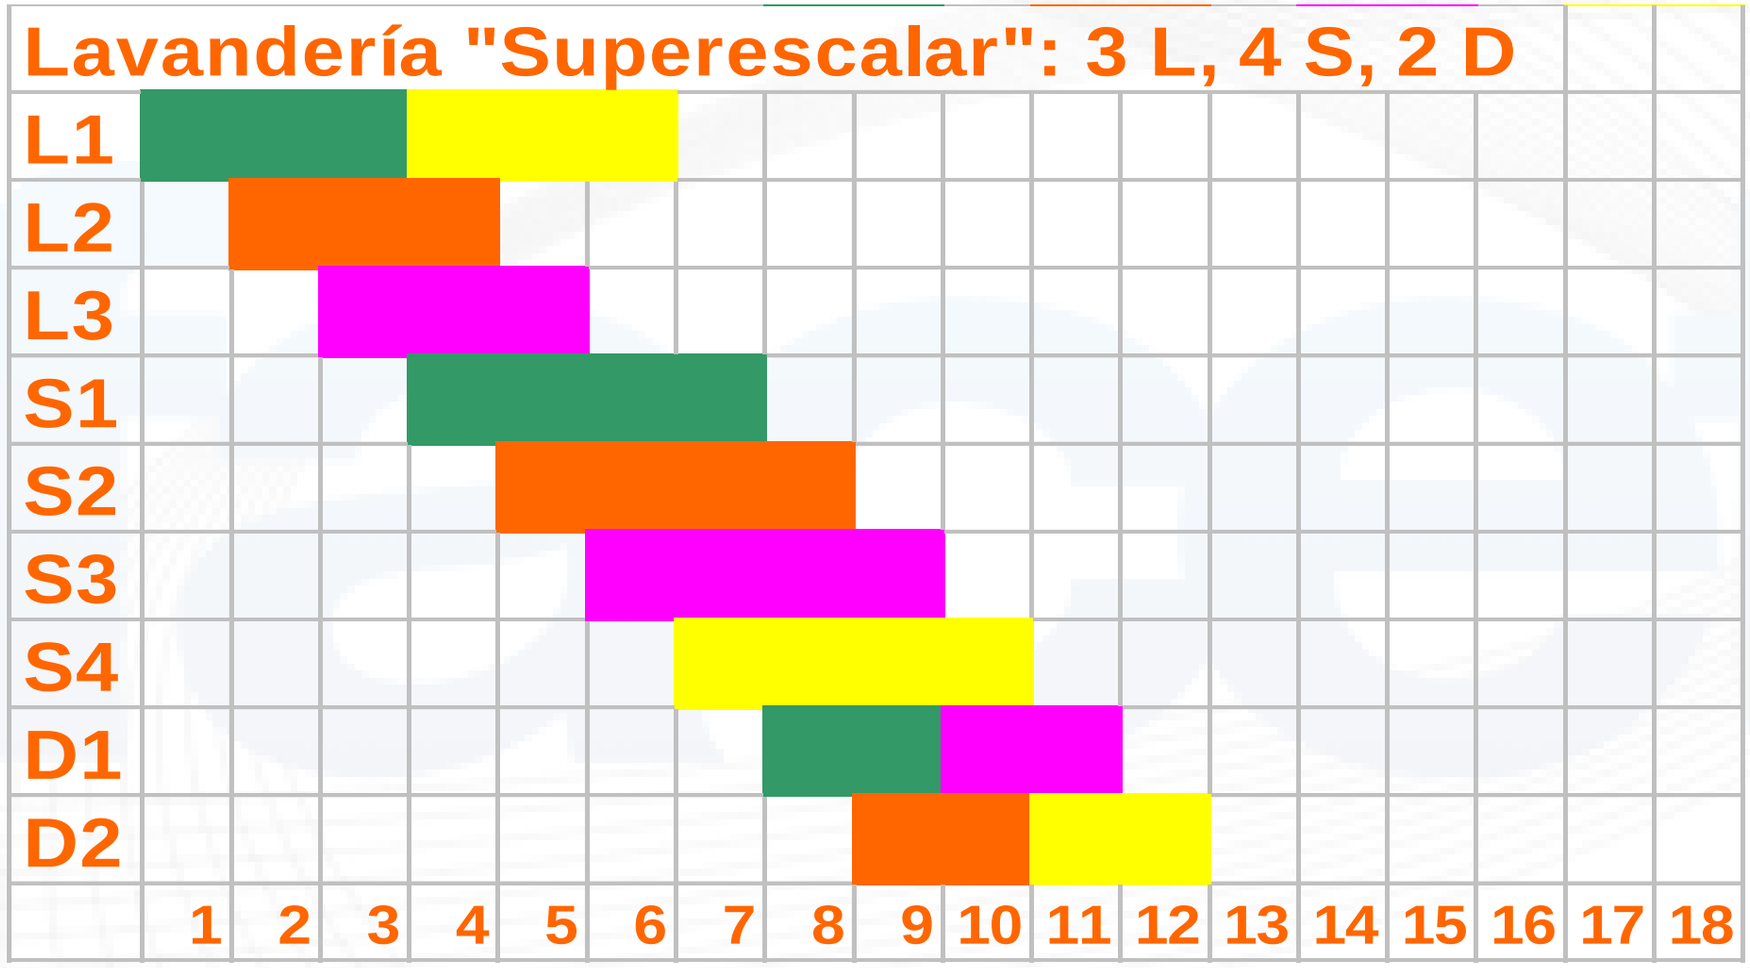

- *¿Nueva productividad?*

Cuellos de botella – Solución extrema

- La productividad es máxima.
  - Limitada por el m.c.d. de las duraciones de los componentes.
- Aumenta significativamente el costo.
  - Dependerá de los objetivos si vale la pena o no.
- En microprocesadores, esta solución se conoce como “superescalar”.
  - La veremos con más detalle en el Tema 09.

Pipelining – Tareas diferentes

- Suponga una secuencia de tareas de distinto tipo:
  - Las tareas tipo 1 usan todas las etapas.
  - Las tareas tipo 2 usan etapas 1, 3 y 5.
  - Las tareas tipo 3 usan etapas 1, 2 y 5.
- ¿Alternativas de solución?
  - En todas se producen choques. Riesgos estructurales.
- Conviene hacer que todas las tareas pasen por todas las etapas
  - Aunque no se haga nada útil en las mismas.
- Ejemplo típico de una mezcla de instrucciones de un procesador.

Pipelining – Ejemplo con circuitos

- Dado un circuito combinacional que posee un retardo T, con un delay de registros C, el tiempo de ciclo sería T+C.

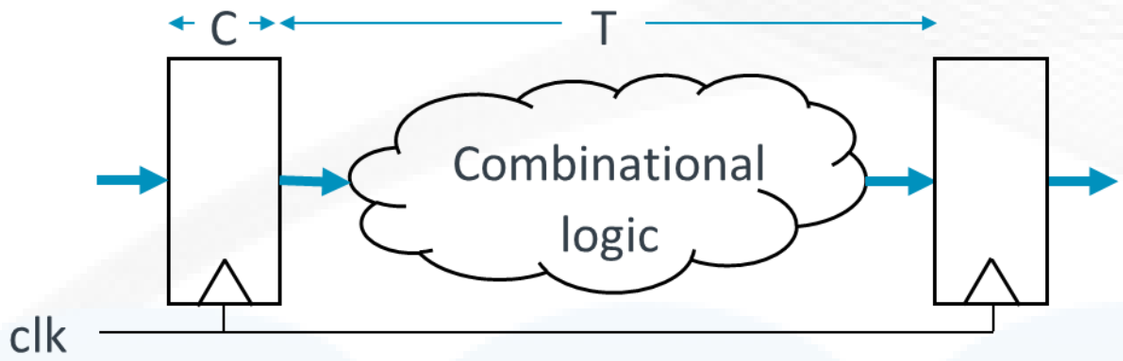

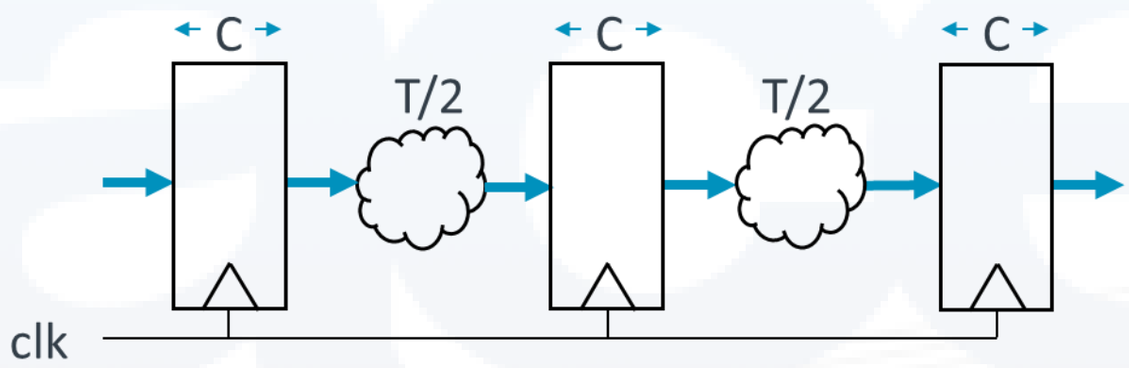

- Se podría agregar un registro intermedio, para dividir la lógica combinacional en dos mitades, y el nuevo tiempo de ciclo pasaría a ser T/2+C.
  - Si C es pequeño, la frecuencia casi que se duplica.

Pipelining – Ejemplo con circuitos

- Dado un sumador de 4 bits en cascada:

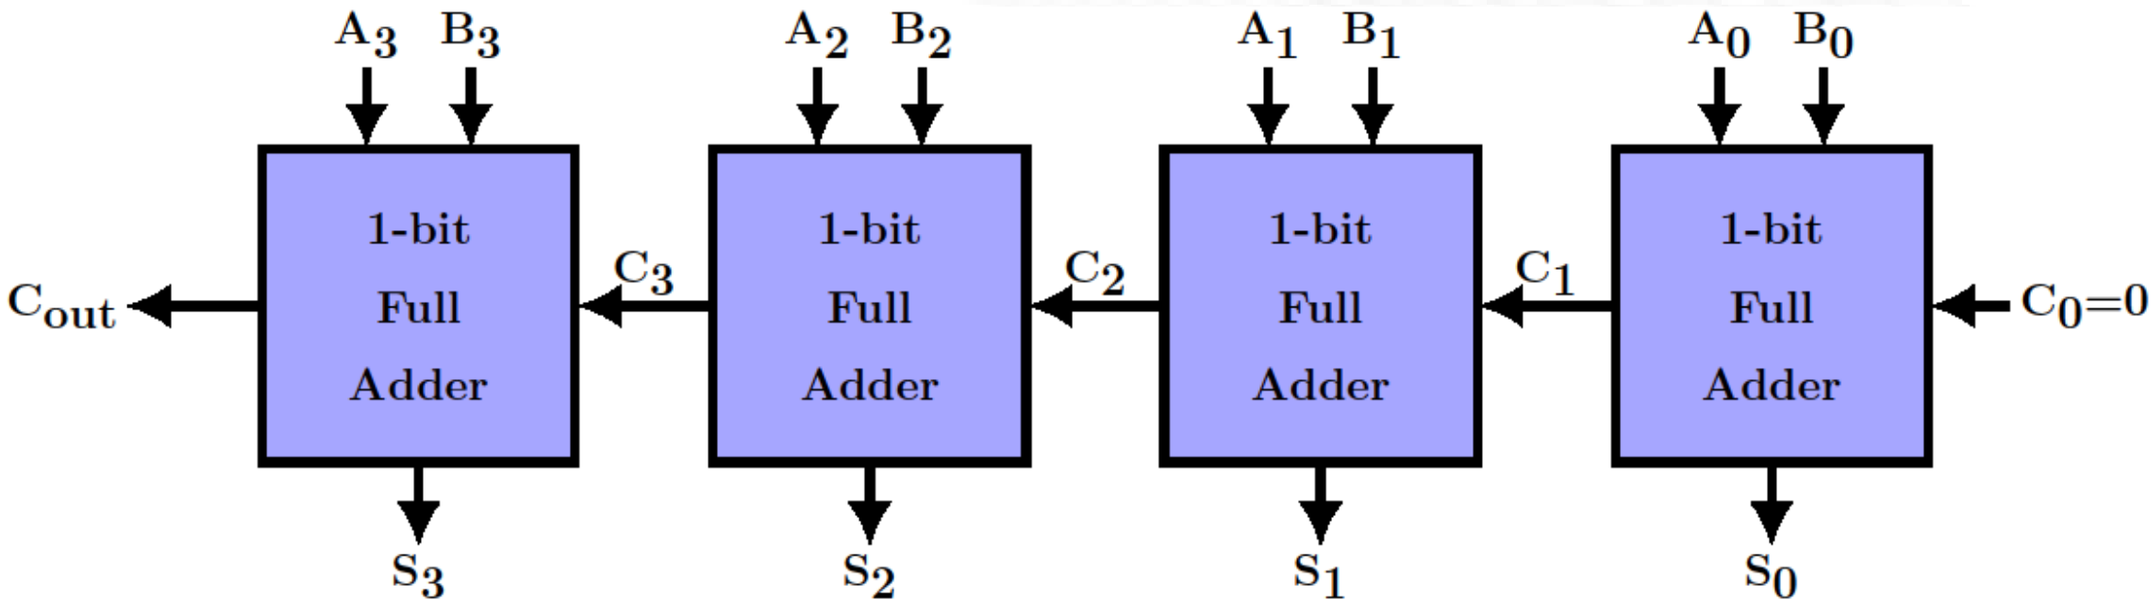

- Suponiendo que cada sumador de 1 bit tiene un retardo lógico igual a T, *¿cuánto se demora en entregar un resultado estable?*
- Suponiendo que mi tarea consiste en realizar 1000 sumas, *¿cuánto demoraría?*

Pipelining – Sumador segmentado

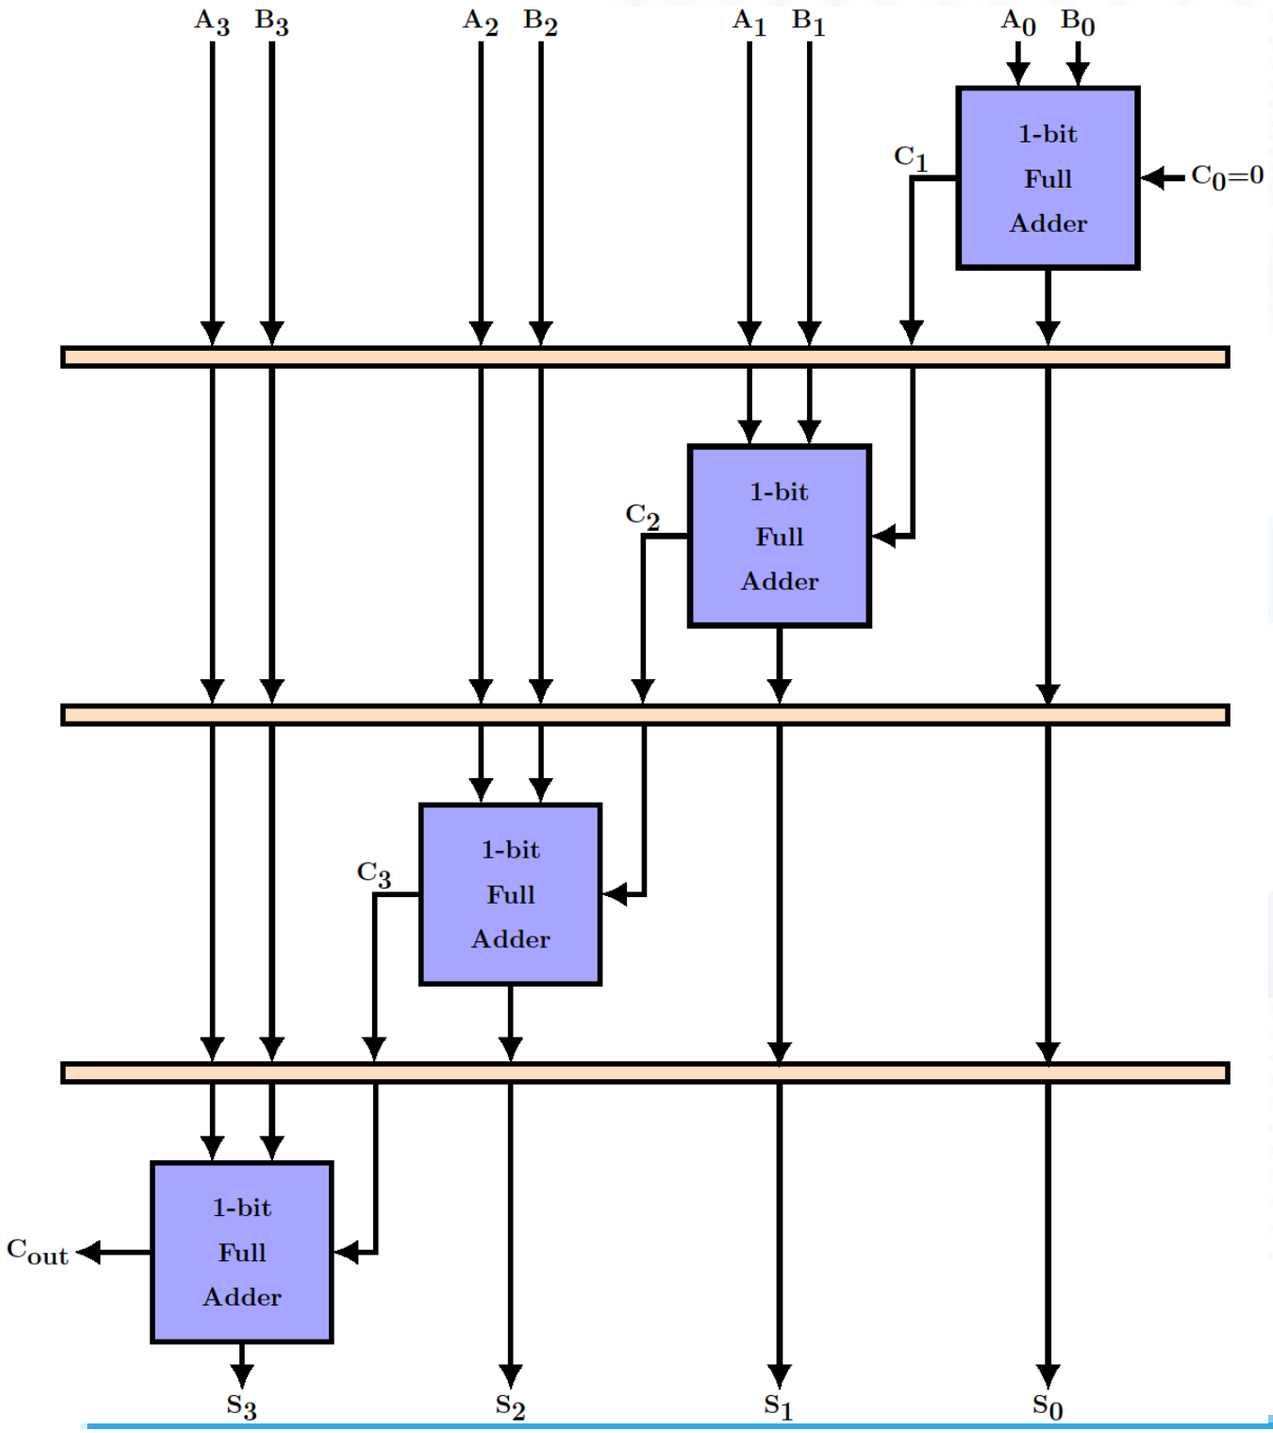

- Se agregan registros intermedios (buffers) para separar en etapas.
  - En cada etapa los datos siempre se toman desde un registro, y terminan en otro registro.
  - Suponemos que estos registros tienen un retardo despreciable.
- *¿Latencia de una suma?*
- *¿Latencia de las 1000 sumas?*
- *¿Productividad?*
- **Atención:** no siempre es posible despreciar el retardo de los buffers.

Recapitulación

- Paralelismo y Pipelining son muy útiles cuando hay muchas tareas repetitivas.
- Paralelismo
  - Hay que multiplicar recursos.
  - Tareas **independientes** en un momento dado.
  - Tasa de salida ideal = m*tasa(serie)
    - Con adecuado perfil de tarea.
- Pipelining
  - Hay que agregar mínimos recursos.
  - Tareas **secuencialmente dependientes**.
  - Tasa de salida ideal= m*tasa(serie)
    - Si las etapas están equilibradas, y trabajando en estado de régimen.
- *¿Puedo hacer que m sea tan grande como se quiera?*

Coordinación y Validez

- Dividir demasiado las tareas altera el modelo
  - ¿Se puede poner menos de un ladrillo?
  - ¿Ajustar menos una tuerca?
  - Los retardos de los buffers intermedios dejan de ser despreciables.
- Se necesitan barreras de sincronización
  - Esta sincronización debe estar expresada en el perfil de la tarea.
    - Todas las paredes deben estar listas antes de poner el techo.
  - Recordar Ley de Amdahl.
- *“Nueve mujeres no pueden tener un bebé en un mes”*.

Diagrama de Precedencia

- Usado para determinar la dependencia entre tareas.
  - Complementa al perfil de la tarea.
- Existen tres tipos de dependencias:
  - Verdaderas dependencias.
    - Hay un verdadero pase de información entre las tareas.
  - Dependencias de salida.
  - Anti dependencias.
- Las dos últimas son agrupadas como “dependencias de nombre”.
  - A pesar de no ser verdaderas, pueden causar problemas.

Tipos de Dependencias

- Verdaderas dependencias: RAW (*Read-After-Write*).
  - Cuando una instrucción j usa (lee) un dato que es escrito por una instrucción i previa.
  - LDR **X1**, [X2]
    ADD X1, **X1**, X3
- Dependencias de salidas: WAW (*Write-After-Write*).
  - Cuando una instrucción j escribe un dato que es escrito por una instrucción i previa.
  - LDR **X1**, [X2]
    ADD **X1**, X1, X3
- Anti dependencias: WAR (*Write-After-Read*).
  - Cuando una instrucción j escribe un dato que es leído por una instrucción i previa.
  - ADD X1, X1, **X3**
    LDR **X3**, [X2], #4

Diagrama de Precedencia

- Veamos un ejemplo con un programa en pseudocódigo, donde todas las instrucciones demoran 1 T, y trabajan sobre registros.

Diagrama de Precedencia - Ejemplo

1. MUL B,B,C B=B*C
2. ADD B,B,D B=B+D
3. ADD C,C,D C=C+D
4. DIV D,D,E D=D / E
5. MOV A,C A=C
6. ADD D,E,A D=E+A
7. MOV D,X D=X

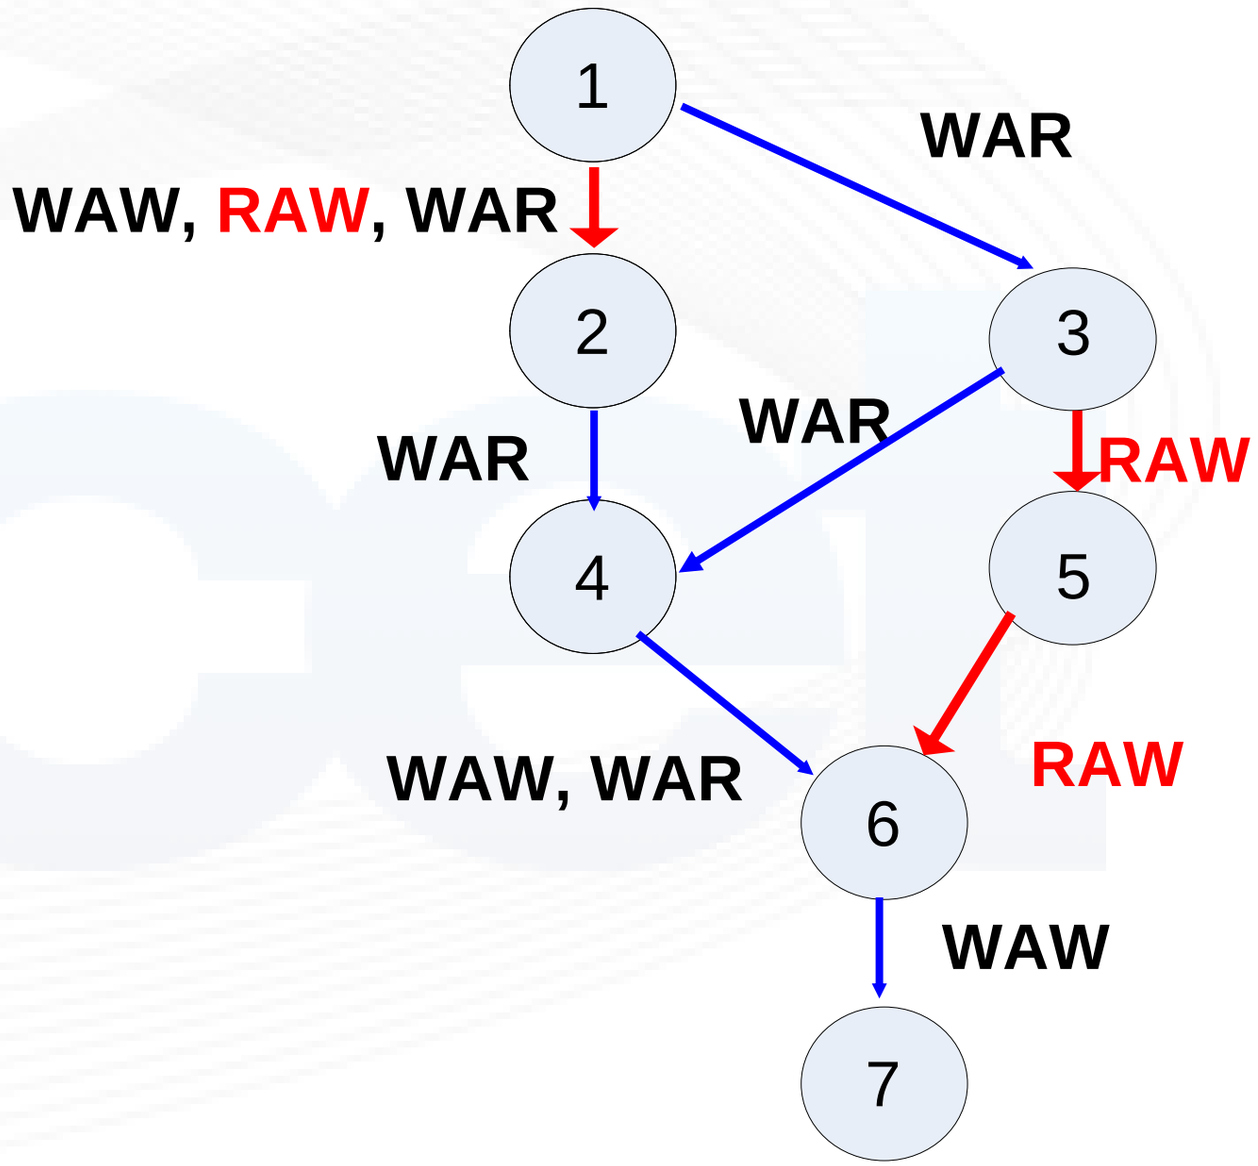

- Tiempo serie = 7T
- Tiempo paralelo = 5T
- ¿Grado de paralelismo?
- ¿Aceleración? ¿Eficiencia?
- Las dependencias son una triste realidad.

Diagrama de Precedencia - Ejemplo

1. MUL B,B,C — B=B*C
2. ADD B,B,D — B=B+D
3. ADD **Q**,C,D — Q=C+D
4. DIV **Y**,D,E — Y=D / E
5. MOV A,**Q** — A=Q
6. ADD D,E,A — D=E+A
7. MOV **Z**,X — Z=X

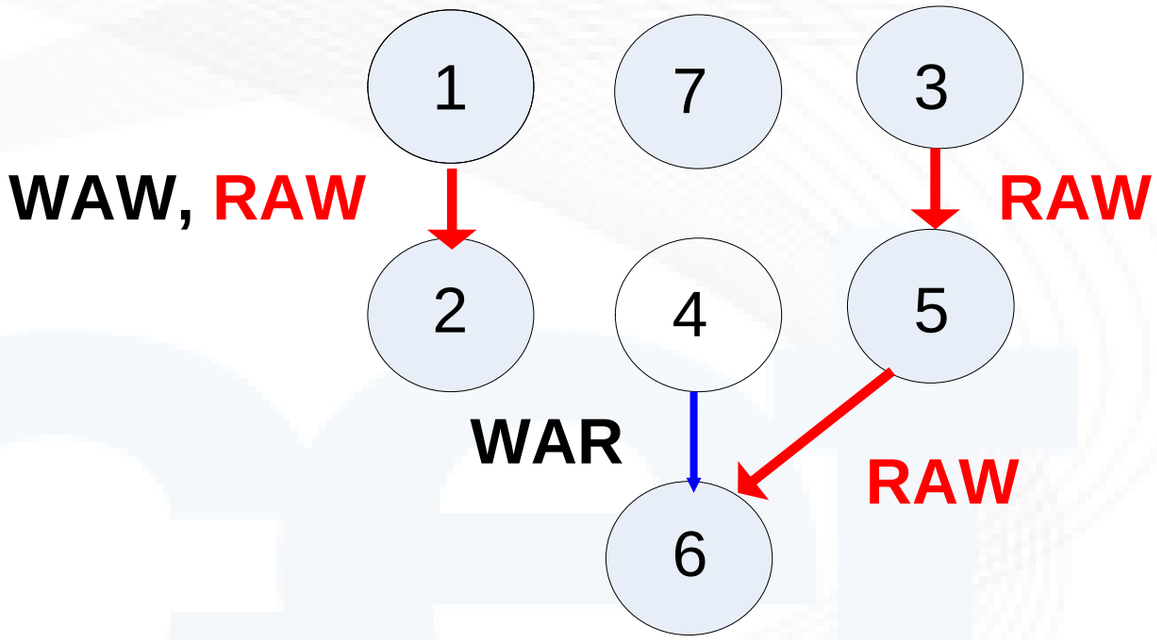

- Tiempo serie = 7T
- Tiempo paralelo = 3T
- ¿Grado de paralelismo?
- ¿Aceleración? ¿Eficiencia?
- Ejecución y terminación fuera de orden.

Paralelismo en memorias DRAM

- Las memorias DRAM tienen un tiempo de ciclo.
  - Indica cada cuánto se puede iniciar un acceso.
- También tienen un tiempo de acceso.
  - Indica cuándo está disponible un dato, desde que se inició el acceso.
- Normalmente el tiempo de acceso es mucho menor que el tiempo de ciclo.

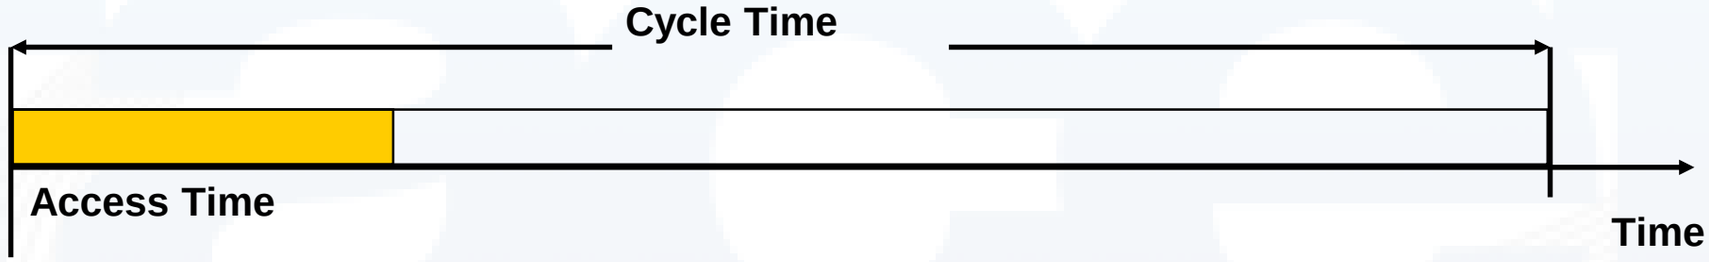

- Si se tiene un solo módulo de memoria, los acceso serían secuenciales:

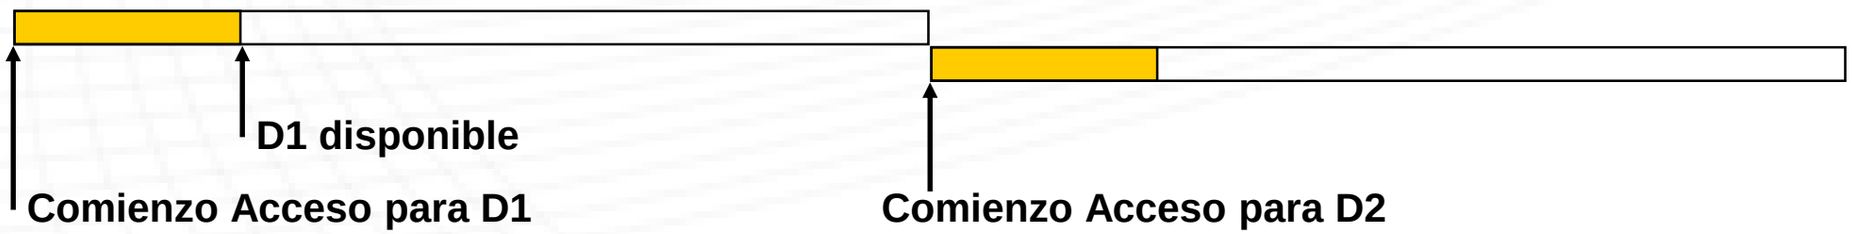

Interleaving de memoria

- Se busca optimizar los accesos a memoria dividiéndola en varios bancos, para aprovechar la diferencia entre tiempo de acceso y tiempo de ciclo.
  - Mientras se espera el tiempo de ciclo, se accede a otro banco.
  - La cantidad de bancos óptima viene dada por la relación entre tiempo de ciclo y tiempo de acceso.
  - Los bancos son conjuntos disjuntos, no copias.
- Por ejemplo, con cuatro módulos de memoria entrelazados sería algo así:

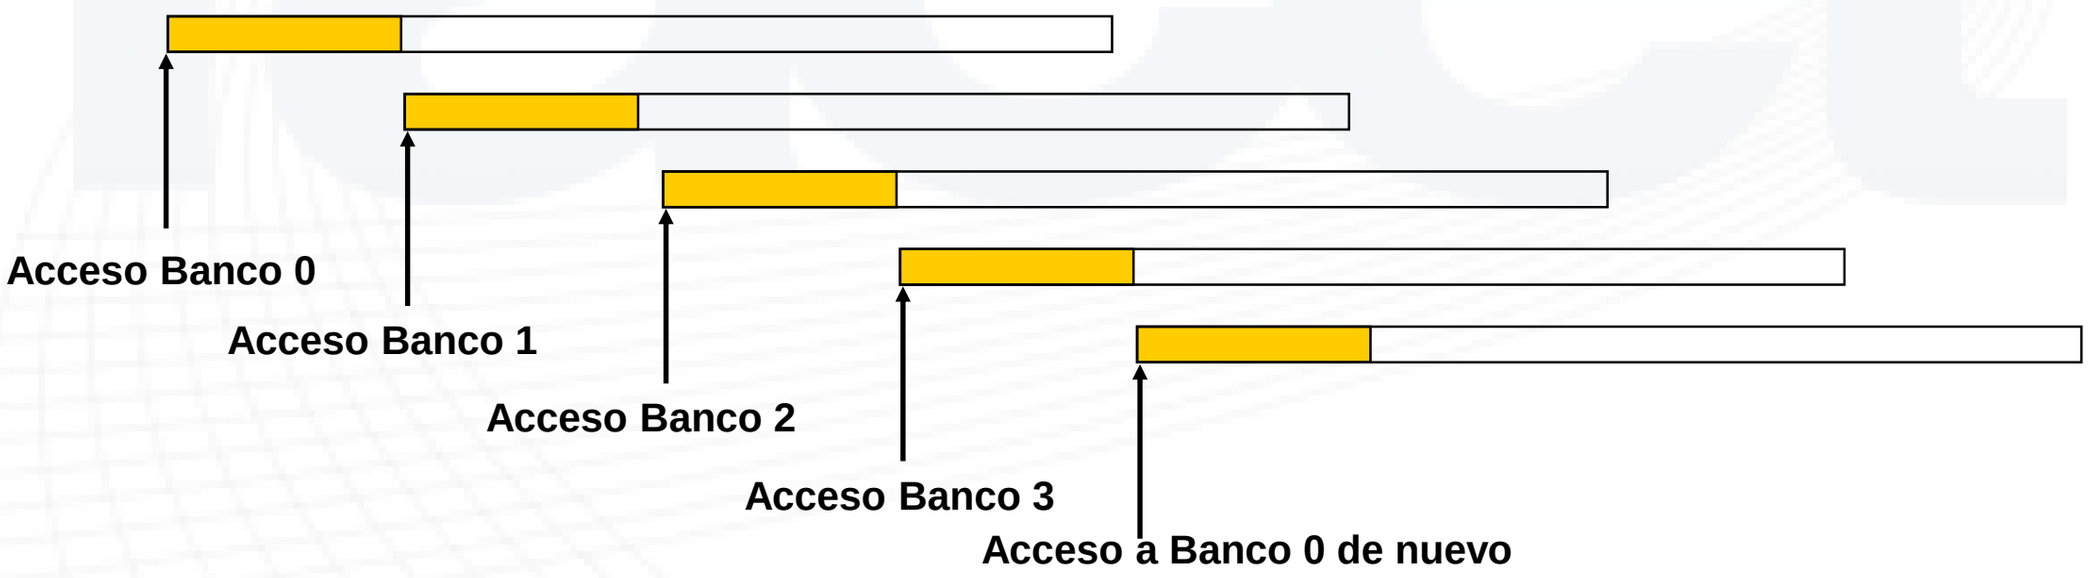

Consideraciones sobre *Interleaving*

- Se usan los bits menos significativos de la dirección para seleccionar el banco correspondiente.
- Aumenta el ancho de banda a memoria.
- Similar a un pipeline de 4 etapas.
- Ideal con accesos consecutivos a memoria.
  - *¿Qué pasa si los accesos no son consecutivos?*

- Con un factor de *interleaving* de 100 y con accesos al azar, en promedio mejora 12 veces.
  - *¿Cuánto mejoraría en este caso si los accesos fueran consecutivos?*

Resumen final

- Métricas importantes:
  - Productividad, Latencia, Aceleración y Rendimiento.
- Herramientas importantes:
  - Perfil de la tarea.
  - Diagrama de precedencias.
- Pipelining ideal: 1 tarea en cada T.
  - Problemas: cuellos de botella, diferentes tareas, otros.
- Paralelismo + Pipelining = Superescalar.
- Ejemplos:
  - Sumador segmentado
  - Interleaving de memoria.

Agradecimientos

- Las diapositivas de este tema fueron basadas en las realizadas por el Ing. Daniel Cohen.
- A su vez inspiradas en las clases del curso CS152 de la Universidad de Berkeley, California, USA.
  - Realizadas por los Prof. D. A. Patterson, John Lazzaro, Krste Asanovic.