

OPERATING SYSTEM

Lecture Notes

Dr. Professor, J.M. Khalifeh

قسم المعلوماتية

الوحدة الرابعة

النسخة العربية

Unit-4

CPU Scheduling

ملخص

جدولة وحدة المعالجة المركزية هي عملية تسمح لعملية واحدة باستخدام وحدة المعالجة المركزية بينما تتأخر عملية أخرى (في وضع الاستعداد) بسبب عدم توفر أي موارد مثل الإدخال / الإخراج وما إلى ذلك، وبالتالي الاستعادة الكاملة من وحدة المعالجة المركزية. الغرض من جدولة وحدة المعالجة المركزية هو جعل النظام أكثر كفاءة وأسرع وعدالة. تحدد جدولة وحدة المعالجة المركزية الطريقة والترتيب الذي يجب تنفيذ العمليات به. في أنظمة التشغيل الحديثة، تتم جدولة مؤشرات الترابط على مستوى kernel - وليس العمليات - في الواقع بواسطة نظام التشغيل. ومع ذلك، غالبًا ما يتم استخدام المصطلحين "جدولة العملية" و "جدولة المسلك" ليشيران إلى نفس المفهوم في هذه الوحدة وسنستخدم جدولة العملية عند مناقشة مفاهيم الجدولة العامة. سنقدم هنا مفاهيم أساسية لجدولة وحدة المعالجة المركزية وأنواع جدولة وحدة المعالجة المركزية والمعايير التي تأخذها وحدة المعالجة المركزية في الاعتبار أثناء عمليات "الجدولة"، كما نقدم العديد من خوارزميات جدولة وحدة المعالجة المركزية، أما ما يتعلق بجدولة النظم متعددة المعالجات والمتعددة النواة ونظم الزمن الحقيقي فسيتم تأجيل جدولتها إلى نظم التشغيل المتقدمة.

أهداف الوحدة

- وصف خوارزميات جدولة وحدة المعالجة المركزية المختلفة.
- تقييم خوارزميات جدولة وحدة المعالجة المركزية على أساس معايير الجدولة.
- وصف خوارزميات الجدولة المستخدمة في أنظمة التشغيل Windows و Linux و Solaris.
- تقييم خوارزميات جدولة وحدة المعالجة المركزية.
- تصميم البرامج التي تنفذ العديد من خوارزميات جدولة وحدة المعالجة المركزية المختلفة.

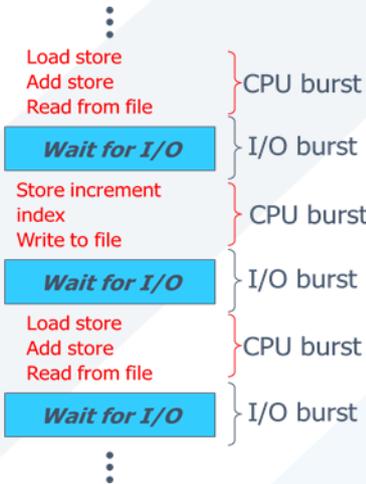
مفاهيم أساسية

يتم تنفيذ جميع البرامج تقريبًا على شكل تتالي دورات معينة من العمليات في وحدة المعالجة المركزية وانتظار إدخال/إخراج من نوع ما.

يتم في الأنظمة البسيطة تشغيل عملية واحدة، وهنا يهدر الوقت المستغرق في انتظار الإدخال/الإخراج، وتضيع دورات وحدة المعالجة المركزية هذه دون فائدة.

أما في أنظمة البرمجة المتعددة، فإن نظام الجدولة يسمح لعملية واحدة باستخدام وحدة المعالجة المركزية بينما تنتظر أخرى الإدخال/الإخراج، وبالتالي الاستفادة الكاملة من دورات وحدة المعالجة المركزية المهدورة.

وهنا فإن التحدي يتمثل في جعل النظام العام "فعالاً" و "عادلاً" قدر الإمكان، ويخضع لشروط متفاوتة ومتغيرة في كثير من الأحيان، وحيثما يكون مصطلح "فعالاً" و "عادلاً" مصطلحات تتعلق بطبيعة التطبيقات وتخضع لتغيير سياسات الأولوية.



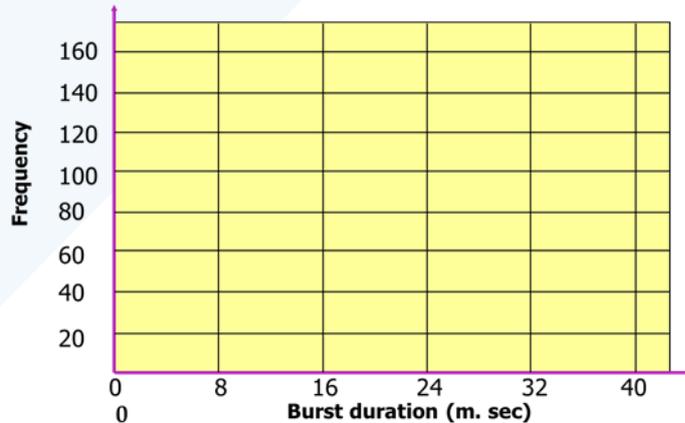
دورة التبادل بين دفعات وحدة المعالجة المركزية و I / O

تتناوب جميع العمليات تقريبًا بين حالتين يتم في كل منهما تنفيذ دفعة، وذلك في دورة مستمرة، كما هو موضح في الشكل:

دفعة وحدة المعالجة المركزية لإجراء العمليات الحسابية، و

دفعة I/O، في انتظار نقل البيانات داخل أو خارج النظام.

تختلف دفعات وحدة المعالجة المركزية من عملية إلى عملية ومن برنامج إلى آخر، لكن دراسة مكثفة تظهر أنماط تكرار مشابهة لتلك الموضحة في الشكل.



جدولة وحدة المعالجة المركزية

عندما تصبح وحدة المعالجة المركزية خاملة، فإن مهمة جدولة وحدة المعالجة المركزية (المعروفة أيضًا باسم جدولة المدى القصير) تتركز على تحديد عملية أخرى من قائمة الانتظار الجاهزة للتشغيل بعد ذلك. لن يتم بناء قائمة الانتظار الجاهزة والخوارزمية المستخدمة لتحديد العملية التالية ليست بالضرورة قائمة على من يأتي أولاً يخدم أولاً. هناك العديد من البدائل للاختيار من بينها، بالإضافة إلى العديد من البارامترات القابلة للتعديل لكل خوارزمية، وهو الموضوع الأساسي لهذه الوحدة بأكملها.

الجدولة الاستيعابية

تتخذ قرارات جدولة وحدة المعالجة المركزية في ظل واحد من أربعة شروط:

1. عندما تنتقل العملية من حالة التشغيل إلى حالة الانتظار، مثل طلب الإدخال/الإخراج أو الانتظار بناء على الاستدعاء (wait).
2. عندما تنتقل العملية من حالة التشغيل إلى حالة الاستعداد، على سبيل المثال استجابة لمقاطعة.
3. عندما تنتقل العملية من حالة الانتظار إلى حالة الاستعداد، عند اكتمال الإدخال/الإخراج أو العودة من wait (مثلاً).
4. عندما تنتهي العملية.

بالنسبة للشرطين 1 و 4، يجب تحديد عملية جديدة، لا يوجد خيار آخر. بالنسبة للشرطين 2 و 3، لدينا الخيار إما لمتابعة تشغيل العملية الحالية، أو تحديد عملية أخرى. إذا كانت الجدولة تتم فقط في ظل الشرطين 1 و 4، فعندها يُقال إن النظام غير استيعابي أو تعاوني. في ظل هذه الظروف، بمجرد أن تبدأ العملية في العمل، فإنها تستمر في العمل، حتى يتم حظرها طواعية أو حتى تنتهي. وإلا يُقال أن النظام استيعابي في غير ذلك من الحالات.

استخدم Windows جدولة غير استيعابية حتى Windows 3.x، وبدأ في استخدام الجدولة الاستيعابية مع Win95. استخدمت أجهزة Mac غير استيعابية قبل OS X، واستيعابية منذ ذلك الحين. لاحظ أن الجدولة الاستيعابية ممكنة فقط على الأجهزة التي تدعم المقاطعة الزمنية.

لاحظ أن الجدولة الاستيعابية يمكن أن تسبب مشاكل عند مشاركة عمليتين للبيانات، لأن عملية واحدة قد تنقطع في منتصف تحديث بنية البيانات المشتركة. وسنعود إلى ذلك في وحدة أخرى من هذا.

يمكن أن يكون الاستيعابي أيضًا مشكلة إذا كانت النواة مشغولة في تنفيذ استدعاء النظام (على سبيل المثال، عند تحديث هياكل بيانات kernel الهامة) عند حدوث الاستيعاب. تتعامل معظم أنظمة UNIX الحديثة مع هذه المشكلة عن طريق جعل العملية تنتظر حتى تكتمل مكاملة النظام أو يتم حظرها قبل السماح بالإجراءات الاستيعابية لسوء الحظ، فإن هذا الحل يمثل مشكلة لأنظمة الزمن الحقيقي، حيث لا يعود من الممكن ضمان الاستجابة في الوقت المطلوب.

تحمي بعض الأقسام الهامة من التعليمات البرمجية نفسها من مشاكل التزامن عن طريق تعطيل المقاطعات قبل الدخول إلى القسم الحرج وإعادة تمكين المقاطعات عند الخروج من القسم. وغني عن القول أنه يجب أن يتم ذلك فقط في

حالات نادرة، و فقط على أجزاء قصيرة جداً من التعليمات البرمجية التي ستنتهي بسرعة، (عادةً ما تكون مجرد تعليمات قليلة عن الجهاز).

الموزع Dispatcher

الموزع هو الوحدة النمطية التي تمنح التحكم في وحدة المعالجة المركزية للعملية المحددة من قبل الجدول. تتضمن هذه الوظيفة:

- تبديل السياق.
 - التبديل إلى وضع المستخدم.
 - القفز إلى الموقع الصحيح في البرنامج الذي تم تحميله حديثاً.
- يجب أن يكون الموزع أسرع ما يمكن، حيث يتم تشغيله على كل تبديل سياق. يُعرف الوقت الذي يستهلكه الموزع بتأخير التوزيع **dispatch latency**.

5.2 معايير الجدولة

هناك العديد من المعايير المختلفة التي يجب مراعاتها عند محاولة تحديد خوارزمية الجدولة "الأفضل" لحالة وبيئة معينة، بما في ذلك:

- استخدام وحدة المعالجة المركزية: من الناحية المثالية، ستكون وحدة المعالجة المركزية مشغولة بنسبة 100% من الوقت، بحيث يتم إضاعة 0 دورة من دورات وحدة المعالجة المركزية. أما من الناحية العملية فإن استخدام وحدة المعالجة المركزية في النظام الحقيقي يتراوح بين 40% (محملة بشكل خفيف) إلى 90% (محملة بكثافة).
 - الإنتاجية: وهي عدد العمليات المنجزة لكل وحدة زمنية. قد تتراوح من 10 / ثانية إلى 1 / ساعة حسب العمليات المحددة.
 - زمن الانجاز: هو الزمن المطلوب لإكمال عملية معينة، من بدء التقديم حتى الانتهاء.
 - زمن الانتظار: وهو مقدار الزمن الذي تقضيه العمليات في قائمة الانتظار الجاهزة في انتظار دورها للحصول على وحدة المعالجة المركزية.
 - زمن الاستجابة: وهو الزمن الذي يستغرقه برنامج تفاعلي من بداية إصدار الأمر إلى بدء الرد على هذا الأمر. بشكل عام، يريد المرء تحسين متوسط قيمة أحد المعايير (زيادة استخدام وحدة المعالجة المركزية وإنتاجيتها، وتقليل جميع المعايير الأخرى). ومع ذلك، في بعض الأحيان يريد المرء أن يفعل شيئاً مختلفاً، مثل تقليل وقت الاستجابة الأقصى.
- في بعض الأحيان يكون من المرغوب فيه تقليل تباين المعايير عن القيمة الفعلية. أي. يتقبل المستخدمون نظاماً منسجماً يمكن التنبؤ به أكثر من نظام غير منسجم، حتى ولو كان أبطأ قليلاً.

خوارزميات الجدولة

سوف تشرح الفقرات التالية العديد من استراتيجيات الجدولة الشائعة، آخذين بالاعتبار للتبسيط وجود عدد صغير من العمليات وأن كل عملية مخصصة بدفعة زمنية واحدة لشخصيتها من قبل وحدة المعالجة المركزية. من الواضح أن الأنظمة الحقيقية يجب أن تتعامل مع الكثير من العمليات المتزامنة التي تنفذ دورات من تخصيص الدفعات الزمنية التي تتوزع بين المعالج والمدخلات والمخرجات.

خوارزمية الجدولة الخدمة FCFS

FCFS أي من يأتي أولاً يُخدم أولاً: وهي خوارزمية بسيطة للغاية. هي مجرد قائمة انتظار FIFO، مثل الزبائن الذين ينتظرون في طابور في البنك أو مكتب البريد أو في آلة النسخ. ومع ذلك، لسوء الحظ، يمكن أن ينتج عن FCFS متوسط فترات انتظار طويلة جداً، خاصة إذا كانت العملية الأولى للوصول إلى هناك تستغرق وقتاً طويلاً. على سبيل المثال، ضع في اعتبارك العمليات الثلاث التالية:

Process	Burst Time
P1	24
P2	3
P3	3

في مخطط Gantt الأول أدناه، تصل العملية P1 أولاً. متوسط وقت الانتظار للعمليات الثلاث (0 + 24 + 27) / 3 = 17.0 مللي ثانية.



في مخطط Gantt الثاني، يبين أنه لو الأقصر أولاً فسينخفض متوسط زمن الانتظار إلى (0 + 3 + 6) / 3 = 3.0 مللي ثانية. إجمالي زمن الانجاز للدفعات الثلاث هو نفسه، ولكن في الحالة الثانية، تنتهي عمليتان من الثلاثة بشكل أسرع، وتتأخر العملية الأخرى بمقدار قصير فقط.

يمكن لـ FCFS أن يحظر تشغيل عمليات ذات دفعات زمنية صغيرة انتظاراً لتنفيذ عملية ذات دفعة زمنية كبيرة لأنها تمتلك أولوية القدوم أولاً. وهذا ما يعرف بتأثير القافلة. عندما تحظر إحدى العمليات ذات الدفعات الكبيرة وحدة المعالجة المركزية، فمثلاً يمكن حظر عدد من عمليات الإدخال / الإخراج انتظاراً لفرغ مشغولية المعالج، مما يترك أجهزة الإدخال / الإخراج في وضع الخمول. عندما تتخلى العملية عن وحدة المعالجة المركزية أخيراً، فإن عمليات الإدخال / الإخراج تمر عبر وحدة المعالجة المركزية بسرعة، مما يترك وحدة المعالجة المركزية في وضع الخمول بينما يصطف الجميع في قائمة الانتظار للإدخال / الإخراج، وهكذا في كل طابور.

خوارزمية جدولة المهمة الأقصر زمنياً أولاً، SJF

تكمن الفكرة وراء خوارزمية SJF في اختيار أسرع مهمة صغيرة يجب القيام بها، وإخراجها من الطريق أولاً، ثم اختيار المهمة التالية الأصغر والأسرع للقيام بها بعد ذلك. (من الناحية الفنية، تختار هذه الخوارزمية عملية ما بناءً على أقصر دفعة زمنية لوحدة المعالجة المركزية التالية، وليس وقت العملية الإجمالي.)
على سبيل المثال، يعتمد مخطط Gantt أدناه على أوقات دفعات وحدة المعالجة المركزية التالية (وافتراض أن جميع الوظائف وصلت في نفس الوقت).

Process	Burst Time
P1	6
P2	8
P3	7
P4	3



في الحالة أعلاه، يكون متوسط وقت الانتظار $7.0 = 4 / (16 + 9 + 3 + 0)$ مللي ثانية، (مقابل 10.25 مللي ثانية لـ FCFS لنفس العمليات.)

يمكن إثبات أن SJF هو أسرع خوارزمية جدولة، لكنه يعاني من مشكلة واحدة مهمة: كيف تعرف كم من الوقت ستستغرق دفعة وحدة المعالجة المركزية التالية؟

بالنسبة للوظائف المجمعة طويلة الأجل، يمكن القيام بذلك استناداً إلى الحدود التي يضعها المستخدمون لوظائفهم عند إرسالها، مما يشجعهم على وضع حدود منخفضة، ولكنه يخاطر باضطرارهم إلى إعادة إرسال الوظيفة إذا قاموا بتعيين حد منخفض. ومع ذلك، فإن ذلك لا يعمل مع جدولة وحدة المعالجة المركزية قصيرة المدى على نظام تفاعلي. قد يكون الخيار الآخر هو قياس خصائص وقت التشغيل للوظائف إحصائياً، لا سيما إذا تم تشغيل نفس المهام بشكل متكرر ومتوقع. ولكن مرة أخرى، هذا ليس خياراً قابلاً للتطبيق لجدولة وحدة المعالجة المركزية قصيرة المدى في العالم الحقيقي.

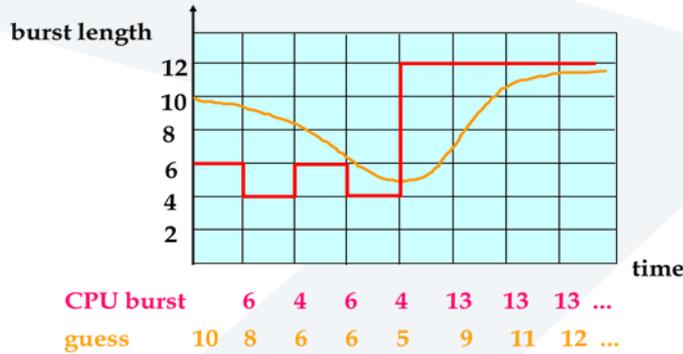
نهج أكثر عملية هو التنبؤ بطول الرشفة التالية، بناءً على بعض القياسات السابقة لأوقات الرشفات الحديثة لهذه العملية. طريقة واحدة بسيطة وسريعة ودقيقة نسبياً هي المتوسط الأسي، والذي يمكن تعريفه على النحو التالي.

$$\tau_{n+1} = \alpha t_n + (1-\alpha)\alpha t_{n-1} + (1-\alpha)^2 \alpha t_{n-2} + \dots (1-\alpha)^{n+1} \tau_0$$

$$\alpha = 1/2 \text{ عند}$$

$$\tau_{n+1} = \left(\frac{1}{2}\right)t_n + \left(\frac{1}{2}\right)^2 t_{n-1} + \left(\frac{1}{2}\right)^3 t_{n-2} + \dots \left(\frac{1}{2}\right)^{n+1} \tau_0$$

يتم تعيين ألفا الأكثر شيوعاً عند 0.5، كما هو موضح في الشكل 5.3:



يمكن أن يكون SJF استيلائياً أو غير استيلائياً. يحدث الاستيلاء عندما تصل عملية جديدة إلى قائمة الانتظار الجاهزة التي لها دفعة متوقعة أقصر من الوقت المتبقي في العملية التي تكون دفعتها حالياً في وحدة المعالجة المركزية. يشار إلى SJF الاستيلائياً أحياناً على أنه أقصر وقت متبقي بداية الجدولة. على سبيل المثال، يعتمد مخطط Gantt التالي على البيانات التالية:

Process	Arrival Time	Burst Time
P1	0	7
P2	2	4
P3	4	1
p4	5	4

SJF (non-preemptive)



$$\text{Average waiting time} = (0 + 6 + 3 + 7)/4 = 4$$

$$\text{Average Turned around time} = (7 + 4 + 10 + 11)/4 = 8$$

SJF (preemptive)



$$\text{Average waiting time} = (9 + 1 + 0 + 2)/4 = 3$$

$$\text{Average Turned around time} = (16+1+5+6)/4=7$$

Preemptive AWT < non Preemptive AWT

خوارزمية الجدولة القائمة على الأولوية

جدولة الأولوية هي حالة أكثر عمومية لـ SJF، حيث يتم تعيين أولوية لكل وظيفة ويتم جدولة الوظيفة ذات الأولوية القصوى أولاً. (يستخدم SJF معكوس وقت الدفعة المتوقع التالي كأولويته - كلما كانت الدفعة المتوقعة أصغر، زادت الأولوية.)

لاحظ أنه من الناحية العملية، يتم تنفيذ الأولويات باستخدام الأعداد الصحيحة ضمن نطاق ثابت، ولكن لا توجد اتفاقية متفق عليها حول ما إذا كانت الأولويات "العالية" تستخدم أعدادًا كبيرة أو أعدادًا صغيرة. نستخدم هنا عددًا منخفضًا للأولويات العالية، حيث يمثل الصفر أعلى أولوية ممكنة. على سبيل المثال، يعتمد مخطط Gantt التالي على أوقات دفعات العملية والأولويات المبينة في الجدول، ويؤدي إلى متوسط وقت انتظار يبلغ 8.2 مللي ثانية:

Process	Burst Time	Priority
P1	10	3
P2	1	1
P3	2	4
P4	1	5
P5	5	2



$$AWT = 8.2$$

$$ATAT = (1+6+16+18+19)/5 = 12$$

يمكن تعيين الأولويات إما داخليًا أو خارجيًا. يتم تعيين الأولويات الداخلية بواسطة نظام التشغيل باستخدام معايير مثل متوسط وقت الدفعة، ونسبة نشاط وحدة المعالجة المركزية إلى نشاط الإدخال/الإخراج، واستخدام موارد النظام، والعوامل الأخرى المتاحة للنواة. يتم تحديد الأولويات الخارجية من قبل المستخدمين، بناءً على أهمية الوظيفة، والرسوم المدفوعة، والسياسة، وما إلى ذلك.

يمكن أن تكون جدولة الأولوية استيلائية أو غير استيلائية.

يمكن أن تعاني جدولة الأولويات من مشكلة كبيرة تُعرف بالحظر غير المحدود لبعض العمليات، أو التجويع، حيث يمكن أن تنتظر مهمة ذات أولوية منخفضة إلى الأبد نظرًا لوجود دائمًا بعض الوظائف الأخرى التي لها أولوية أعلى.

إذا تم السماح بحدوث هذه المشكلة، فسيتم تشغيل العمليات في النهاية عندما يخف تحميل النظام (في الساعة 2:00 صباحًا على سبيل المثال)، أو ستضيق في النهاية عند إيقاف تشغيل النظام أو تعطله. (وهناك شائعات عن وظائف عالقة منذ سنوات).

أحد الحلول الشائعة لهذه المشكلة هو التقييم العمري للعمليات، حيث تزداد أولويات الوظائف كلما طال انتظارها. بموجب هذا المخطط، ستحصل الوظيفة ذات الأولوية المنخفضة في النهاية على أولويتها مرتفعة بدرجة كافية ليتم تشغيلها.

الأولويات الداخلية والخارجية

تستخدم الأولويات المحددة داخليًا بعض الكميات القابلة للقياس لحساب أولوية العملية. على سبيل المثال:

- حدود الوقت
- متطلبات الذاكرة
- عدد الملفات المفتوحة

- تم استخدام نسبة متوسط اندفاع الإدخال / الإخراج إلى متوسط اندفاع وحدة المعالجة المركزية في أولويات الحوسبة.
- يتم تحديد الأولويات الخارجية من خلال معايير خارجية لنظام التشغيل، مثل
- أهمية العملية
- الأموال التي يتم دفعها لاستخدام الكمبيوتر
- الجهة الراعية للعمل
- العوامل المتعلقة بسياسات التشغيل

خوارزمية الشريط الدوار (RR) Round robin

تشبه جدولة الشريط الدوار جدولة FCFS، باستثناء أنه يتم تعيين دفعات وحدة المعالجة المركزية بحدود تسمى كمية الزمن time quantum.

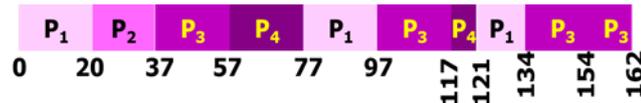
عندما يتم تخصيص وحدة المعالجة المركزية للعملية، يتم تعيين المؤقت بقيمة تم تعيينها لكمية زمنية ما. إذا انتهت دفعة العملية قبل انتهاء فترة المؤقت الكمي، فسيتم إخراجها إلى خارج وحدة المعالجة المركزية تمامًا مثل خوارزمية FCFS العادية.

إذا توقف المؤقت أولاً، فسيتم تبديل العملية من وحدة المعالجة المركزية ونقلها إلى ذيل قائمة الانتظار الجاهزة. يتم الاحتفاظ بقائمة الانتظار الجاهزة كقائمة انتظار دائرية، لذلك عندما يكون لكل العمليات دور، يعطي الجدول العملية الأولى دورًا آخر، وهكذا.

يمكن أن تعطي جدولة RR تأثير مشاركة جميع المعالجات في وحدة المعالجة المركزية بشكل متساوٍ، على الرغم من أن متوسط وقت الانتظار يمكن أن يكون أطول من خوارزميات الجدولة الأخرى. في المثال التالي، يبلغ متوسط وقت الانتظار 5.66 ملي ثانية.

مثال على RR مع كم الوقت = 20

Process	Burst Time
P1	53
P2	17
P3	68
P4	24

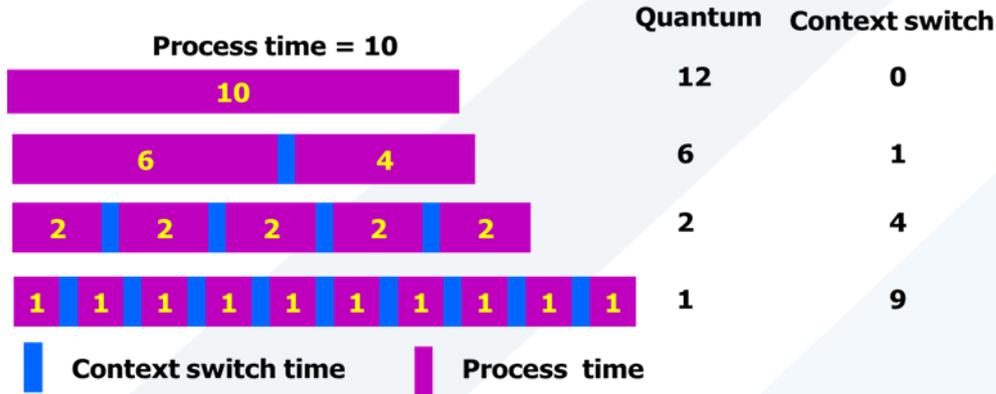


$$ATAT_{(RR)} = (134+37+121+162)/4=113.5$$

$$ATAT_{(SJF)} = (17+41+94+162)/4=78.5$$

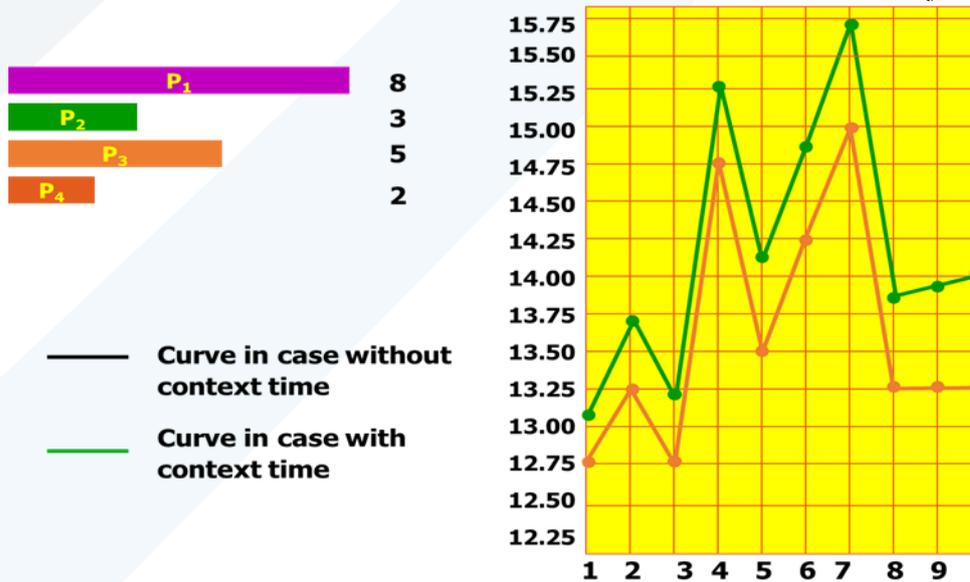
$$ATAT_{(FCFS)} = (53+70+138+162)/4=105.75$$

أداء RR حساس لكم الوقت المختار. إذا كان الكم كبيراً بدرجة كافية، فإن RR يعود إلى خوارزمية FCFS؛ إذا كانت صغيرة جداً، فستحصل كل عملية على $n/1$ من وقت المعالج وتشارك وحدة المعالجة المركزية بالتساوي مع بقية العمليات.



ولكن النظام الحقيقي يستدعي زمناً إضافياً لكل تبديل سياق، وكلما قل كم الوقت، زاد عدد مرات التبديل الموجودة في السياق كما في الشكل أدناه. تستخدم معظم الأنظمة الحديثة قيمة لكم الوقت بين 10 و 100 مللي ثانية، وأوقات تبديل السياق من مرتبة 10 ميكروثانية، وبالتالي فإن الزمن الإضافي الناجم عن تبديل السياق يكون صغيراً بالنسبة إلى كم الوقت.

يختلف وقت الدوران أيضاً باختلاف وقت الكم، بطريقة غير ظاهرة. ضع في اعتبارك، على سبيل المثال، العمليات الموضحة في الشكل أدناه:

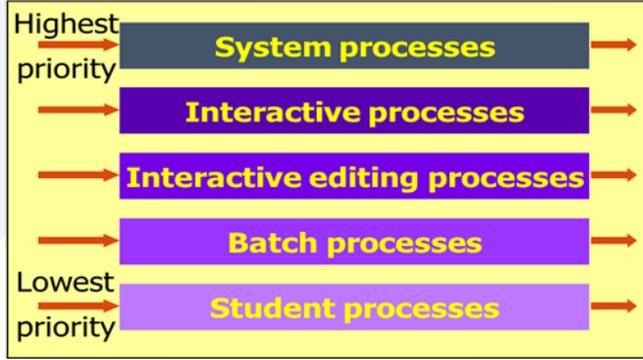


بشكل عام، يتم تقليل وقت الاستجابة إلى الحد الأدنى إذا أنهت معظم العمليات دفعة وحدة المعالجة المركزية التالية في غضون كم الوقت المعطى لمرة واحدة. على سبيل المثال، مع ثلاث عمليات دفعات كل منها 10 مللي ثانية، يكون متوسط وقت الاستجابة من أجل وقت كمي مساو لـ 1 مللي ثانية 29، ويقلل الوقت الكمي المساوي لـ 10 مللي ثانية

وقت الاستجابة إلى 20. ومع ذلك، إذا كانت القيمة كبيرة جدًا، فإن RR يتدهور إلى FCFS. القاعدة الأساسية هي أن 80% من دقات وحدة المعالجة المركزية يجب أن تكون أصغر من الوقت الكمي.

جدولة قائمة الانتظار متعددة المستويات (هذه الفقرة غير مطلوبة في الامتحان الثاني وسيتم شرحها لاحقاً)

عندما يكون بالإمكان تصنيف العمليات بسهولة، فإنه يمكن إنشاء قوائم انتظار منفصلة متعددة، كل منها يمكنه أن يطبق أي خوارزمية جدولة تناسب العمل المطلوب فيه، و/أو تعديل البارامترات بشكل مختلف من مستوى إلى آخر. هنا تكون الجدولة أيضًا بين قوائم الانتظار. هناك خياران شائعان هما الأولوية الصارمة (لا يتم تشغيل أي وظيفة في قائمة انتظار ذات أولوية منخفضة حتى تصبح جميع قوائم الانتظار ذات الأولوية الأعلى فارغة) و round-robin (تحصل كل قائمة انتظار على شريحة زمنية بدورها، ربما بأحجام مختلفة). لاحظ أنه بموجب هذه الخوارزمية لا يمكن التبديل من قائمة انتظار إلى قائمة انتظار أي بمجرد تعيين قائمة انتظار، يتم تفعيل هذه القائمة حتى تنتهي.

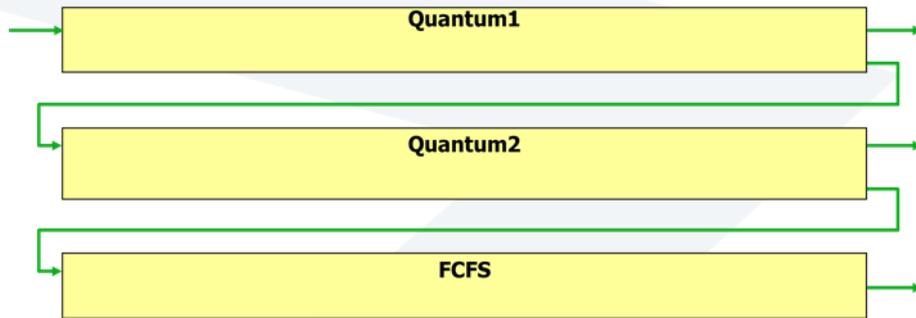


الجدولة متعددة المستويات مع التغذية الراجعة

الجدولة متعددة المستويات مع التغذية الراجعة تشبه الجدولة العادية متعددة المستويات الموصوفة أعلاه، باستثناء أنه يمكن نقل الوظائف من قائمة انتظار إلى أخرى لعدة أسباب منها:

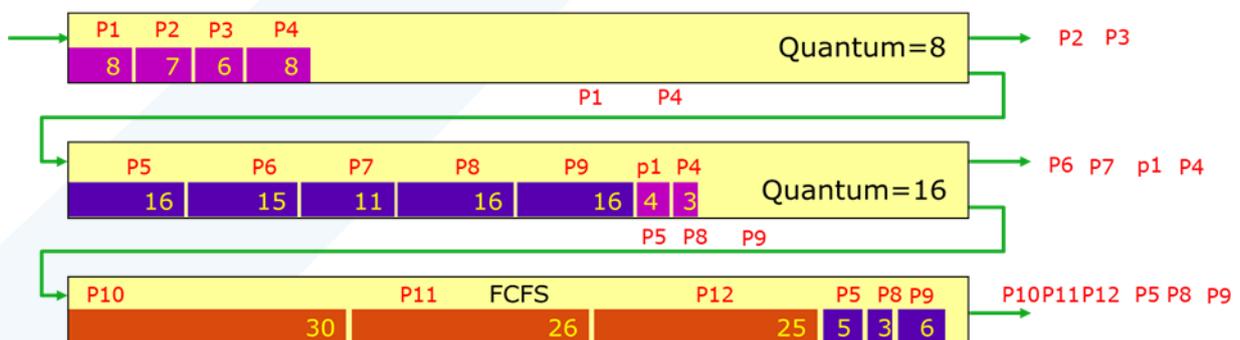
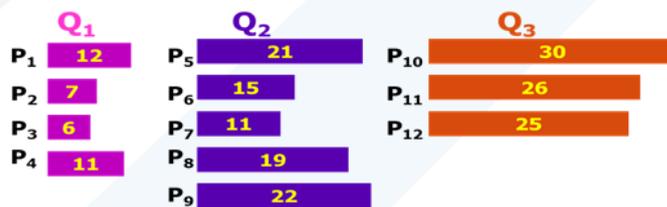
- إذا تغيرت خصائص الوظيفة بين وظيفة تحتاج إلى استخدام مكتب لوحدة المعالجة المركزية واستخدام مكتب للإدخال/الإخراج، عندها قد يكون من المناسب تبديل وظيفة من قائمة انتظار إلى أخرى.
 - كما يمكن أيضًا استخدام التقييم العمري للعمليات، بحيث يمكن لا تضطر الوظيفة ذات الأولوية المنخفضة إلى فترة طويلة للمكوث في القائمة وهي تنتظر العملية ذات الأولوية الأعلى كي تنتهي من استخدام المعالج.
- الجدولة متعددة المستويات مع التغذية الراجعة هي الأكثر مرونة، لأنه يمكن ضبطها لأي موقف. ولكنه أيضًا الأكثر تعقيدًا في التنفيذ بسبب جميع وتعديل البارامترات القابلة للتعديل. تتضمن بعض البارامترات التي تحدد أحد هذه الأنظمة ما يلي:

- عدد قوائم الانتظار.
- خوارزمية الجدولة لكل قائمة انتظار.
- الأساليب المستخدمة لترقية العمليات أو تخفيضها من قائمة انتظار إلى أخرى. (والذي قد يكون مختلفًا).
- الطريقة المستخدمة لتحديد أي قائمة انتظار تدخل العملية في البداية.



Example of Multilevel Feedback Queue

Q1 Quantum=8		Q2 Quantum=16		Q3 FCFS	
Process	Burst Time	Process	Burst Time	Process	Burst Time
P1	53	P5	21	P10	30
P2	17	P6	15	P11	26
P3	68	P7	11	P12	25
P4	24	P8	19		
		P9	22		



Example:

Consider a system that has a CPU-bound process, which requires a burst time of 40 seconds. The multilevel Feed Back Queue scheduling algorithm is used and the queue time quantum '2' seconds and in each level it is incremented by '5' seconds. Then how many times the process will be interrupted and in which queue the process will terminate the execution?

Solution:

Process P needs 40 Seconds for total execution.

At Queue 1 it is executed for 2 seconds and then interrupted and shifted to queue 2.

At Queue 2 it is executed for 7 seconds and then interrupted and shifted to queue 3.

At Queue 3 it is executed for 12 seconds and then interrupted and shifted to queue 4.

At Queue 4 it is executed for 17 seconds and then interrupted and shifted to queue 5.

At Queue 5 it executes for 2 seconds and then it completes.

Hence the process is interrupted 4 times and completed on queue 5.