

# O Modelo de Atores

MCZA020-13 - Programação Paralela

---

Emilio Francesquini

[e.francesquini@ufabc.edu.br](mailto:e.francesquini@ufabc.edu.br)

2020.Q1

Centro de Matemática, Computação e Cognição  
Universidade Federal do ABC



- Estes slides foram preparados para o curso de **Programação Paralela** na UFABC.
- Este material pode ser usado livremente desde que sejam mantidos, além deste aviso, os créditos aos autores e instituições.
- Estes slides contém alguns textos e figuras preparados por **Dror Berezniatsky**.




## A Lei de Moore

---

## A Lei de Moore

*O número de transistores em um chip vai dobrar aproximadamente a cada 18 meses.*

Gordon E. Moore, 1965



## Andy Giveth, and Bill Taketh away

- Não importa o quão rápido os processadores se tornem, o software sempre encontra novas maneiras para consumir o ganho de desempenho.
- Lei de Andy e Bill -  
[https://en.wikipedia.org/wiki/Andy\\_and\\_Bill%27s\\_law](https://en.wikipedia.org/wiki/Andy_and_Bill%27s_law)



## The Free Lunch


Ganhos de desempenho regulares, baratos e "gratuitos" sem nem mesmo ter a necessidade de lançar novas versões. Bastava esperar...

- Este tempo já passou.
- Ótimo artigo do Herb Sutter:

<http://www.gotw.ca/publications/concurrency-ddj.htm>



# The Free Lunch is Over



## Mas por quê não temos processadores de 10GHz hoje em dia?

- No início dos anos 2000 a frequência de funcionamento dos processadores aumentou tanto que:
  - ▶ Os chips ficaram grandes o suficiente para a velocidade da luz ser uma barreira (os sinais não conseguem mais atravessar o chip todo em menos de um ciclo)
  - ▶ Frequências mais altas acabam causando problemas de dissipação de calor



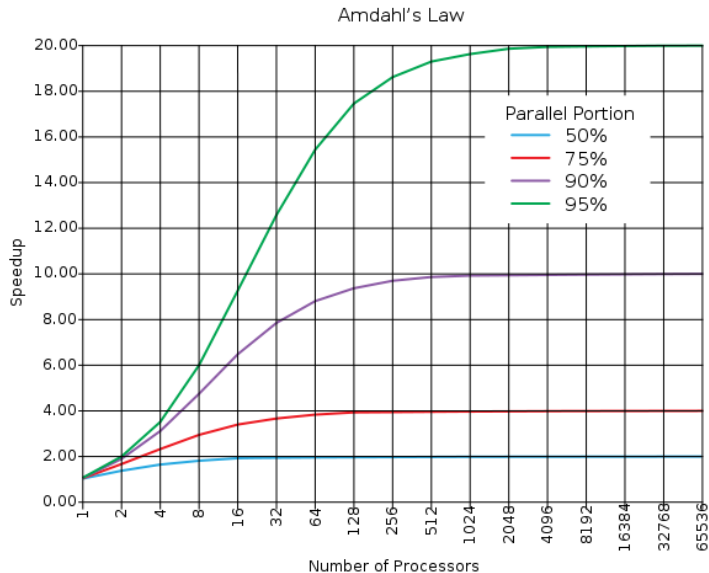
## A era dos Multicores

- Os projetistas de hardware, então, se voltaram à produção de processadores multi-core
  - ▶ A incessante busca de desempenho passou então a ser uma tarefa compartilhada com os desenvolvedores de software
- Aumentam o desempenho total (paralelo) mas não mudam significativamente o desempenho sequencial
- De fato, o desempenho das CPUs tendem a ficar estáveis pelos próximos anos

## A revolução da programação concorrente e paralela

- Acabou a mamata...
- Quer extrair até a última gota de desempenho do seu processador?

Você precisa desenvolver software **concorrente**



# Programação Concorrente com Estado Compartilhado

---

- Há um **compartilhamento de recursos** (variáveis/memória, dispositivos, ...)
- Estabelece-se um **mecanismo de controle e sincronização** de acesso a esses recursos
  - ▶ Travas (locks)
  - ▶ Semáforos
  - ▶ Monitores
  - ▶ ...

- Processos e Threads são a maneira do sistema operacional representar execuções concorrentes
- Threads, por definição, compartilham os recursos do processo ao qual pertencem com as demais threads do mesmo processo.
  - ▶ Exigem mecanismos de sincronização para acesso aos recursos compartilhados para garantir
    - Corretude
    - Consistência

## Threads são utilizados pela maior parte das linguagens tradicionais

- C/C++
- Java
- Python
- C#
- Ruby
- ...





*"Programas multi-threaded não triviais são incompreensíveis para um ser humano..."*

Edward A. Lee, The Problem with Threads

- Diante da dificuldade de se utilizar threads corretamente, passou-se a procurar alternativas
  - ▶ Trocas de mensagens
    - MPI
    - Modelo de Atores
  - ▶ Memória transacional
  - ▶ Dataflow

## O Modelo de Atores

---

Proposto originalmente por Hewitt *et al.* em 1973 e, mais tarde generalizado para concorrência em 1986 por Agha

- Baseado em princípios muito simples
  - ▶ Troca de mensagens assíncronas
  - ▶ Recepção seletiva de mensagens
  - ▶ Área de memória (*heap*) e laço de eventos privados
- Leve
  - ▶ Criado em quantidades excedendo o número de núcleos de processamento
  - ▶ **Desacopla** o número de atores do hardware



- Têm a sua disposição ambientes de execução leves com distribuição automática e transparente de carga
- São altamente otimizados para máquinas com memória compartilhada
- São muito utilizados
  - ▶ **Linguagens:** Erlang, Elixir, Scala, Akka, Kilim, Salsa, ...
  - ▶ **Applications:** WhatsApp, Facebook Chat, Chef Server, Twitter, CouchDB, ...
  - ▶ Atendem milhares de clientes simultaneamente em serviços dedicados executando em máquinas poderosas

- **Atores em vez de objetos**
- **Não há estado compartilhado** entre atores
- Toda comunicação se dá por trocas de **mensagens assíncronas**
  - ▶ As mensagens são imutáveis
- Caixas postais podem fazer um **buffer** das mensagens recebidas
  - ▶ É o único canal de comunicação com um ator e age como uma fila com **múltiplos produtores e um único consumidor**



- Reagir a alguma mensagem recebida executando um comportamento
  - ▶ Eles podem apenas alterar o próprio estado
  - ▶ ...ou mandar mensagens para outros atores.
- Modelo muito mais natural do que o modelo orientado a objetos!
  - ▶ Você é capaz de mudar o estado de algo na cabeça do seu colega? Isto é feito por compartilhamento de estado ou por troca de mensagens?
- Como os atores nunca compartilham o estado, nunca precisam competir por travas para acessar recursos compartilhados

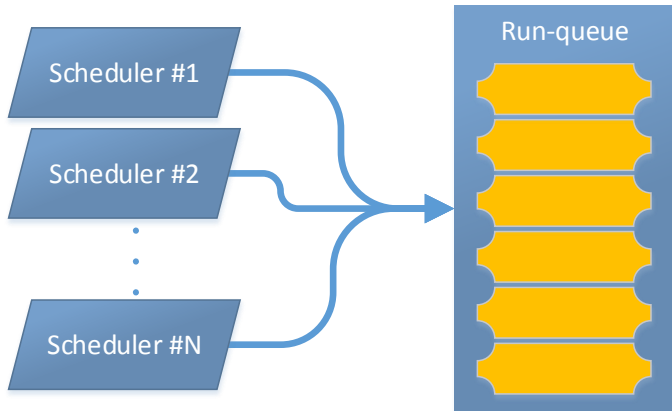
Os ambientes de execução do modelo de atores podem ser divididos em 2 principais categorias:

- Baseados em threads
  - ▶ Tem limitações sobre o número de atores e deixa a cargo do sistema operacional o escalonamento dos atores
- Baseados em eventos
  - ▶ Compostos de filas simples ou múltiplas de onde um pool de threads obtém as tarefas a serem executadas
  - ▶ Sistemas operacionais ainda não estão tão otimizados quanto poderiam para dar suporte a este tipo de aplicações




## Single Run-Queue


- Utilizado por Akka, Kilim, e VMs antigas de Erlang
- Pode se tornar um gargalo no desempenho
- **Não garante** soft-affinity




## Multiple Run-Queues

- Utilizado por Erlang, Kilim
- Colocação inicial/soft affinity
- Balanceamento de carga (baseado no tamanho das filas)
- *Work stealing*





- Vivem pouco (99.5% < 1.5s)
- Tempo de atividade médio 26%
- Atores com vida curta
  - ▶ Representam a maioria dos atores
  - ▶ Geralmente são trabalhadores
  - ▶ Maior atividade
  - ▶ Pela sua grande quantidade dividem o scheduler
- Atores com vida longa
  - ▶ Principalmente inativos
  - ▶ Mantêm o estado da aplicação
- O número de atores é independente do número de núcleos




Analizando uma série de aplicações, percebemos que as mensagens são curtas

<b>Application</b>	<b>Average Message Size</b>
CouchDB	663 Bytes
Sim-Diasca	1088 Bytes
ErlangTW	960 Bytes
<b>ehb</b>	1024 Bytes
<b>big</b>	2112 Bytes
<b>orbit_int</b>	832 – 4608 Bytes

Alguns atores são mais populares que outros


- Natural já que algumas funções são mais requisitadas que outras
- Alguns são atores de coordenação, logo criam mais atores do que um ator comum
- Chamamos esses atores especiais **hubs**
- Os hubs normalmente só conversam com um conjunto pequeno de outros atores chamado de "grupo de afinidade".





CouchDB communication graph

Alguns atores são mais populares que outros

- Natural já que algumas funções são mais requisitadas que outras
- Alguns são atores de coordenação, logo criam mais atores do que um ator comum
- Chamamos esses atores especiais **hubs**
- Os hubs normalmente só conversam com um conjunto pequeno de outros atores chamado de "grupo de afinidade".




CouchDB communication graph





O grafo de comunicação é específico por aplicação

- Neste caso é uma comunicação todos-com-todos
- Relativamente raro



- Ericson AXD 301 switch
  - ▶ Milhões de chamadas por minuto, 99,99999999% uptime
- Aplicação de chat do Facebook
- Servidores do Whatsapp
- RabbitMQ
  - ▶ AMQP de alto desempenho, 400.000 mensagens por segundo
- CouchDB
- Ejabberd XMPP server - [jabber.org](http://jabber.org)

## Benefícios do modelo de atores

- Mais fácil de entender sistemas não triviais
- Nível de abstração alto
- Evita (ou facilita evitar)
  - ▶ Condições de corrida
  - ▶ Impasses
  - ▶ Starvation
  - ▶ Live locks
- Computação distribuída

## Aproximação por trapézios

---

---

```
1 -module(trap).  
2 -export([main/1, go/6, trap/4, trapFold/4]).  
3  
4 -mode(native).  
5  
6 f(X) ->  
7     X * X.
```

---

---

```
1 trap(Left, Right, TrapCount, BaseLen) ->
2     BaseLen * trap2(
3         Left, Right, TrapCount, BaseLen,
4         (f(Left) + f(Right)) / 2.0, 1).
5
6 trap2 (Left, Right, TrapCount, BaseLen, Estimate, I) when I < TrapCount
7     ↪ ->
8     Estimate2 = Estimate + f(Left + I * BaseLen),
9     trap2 (Left, Right, TrapCount, BaseLen, Estimate2, I + 1);
10 trap2 (_, _, _, _, Estimate, _) ->
    Estimate.
```

---

---

```
1 trapFold (Left, Right, TrapCount, BaseLen) ->
2     F = fun (I, Acc) -> Acc + f(Left + I * BaseLen) end,
3     L = lists:seq(1, TrapCount - 1),
4     PartialInt = lists:foldl(F, (f(Left) + f(Right)) / 2.0, L),
5     BaseLen * PartialInt.
```

---

```
1 main([A, B, N, P]) ->
2     A2 = list_to_float(atom_to_list(A)),
3     B2 = list_to_float(atom_to_list(B)),
4     N2 = list_to_integer(atom_to_list(N)),
5     P2 = list_to_integer(atom_to_list(P)),
6     H = (B2 - A2) / N2,
7     Ranks = lists:seq(0, P2 - 1),
8
9     [spawn(trap, go, [self(), Rank, A2, N2, H, P2]) || Rank <- Ranks],
10    Int = lists:sum([getResults(Rank) || Rank <- Ranks]),
11
12    io:fwrite(io_lib:format("~.16f\n", [Int])),
13    init:stop().
```



```
1 go (Src, Rank, A, N, H, P) ->
2   LocalN = N div P,
3   LocalA = A + Rank * LocalN * H,
4   LocalB = LocalA + LocalN * H,
5   %% Descomente a linha abaixo para usar a outra implementação
6   %% LocalInt = trap (LocalA, LocalB, LocalN, H),
7   LocalInt = trapFold (LocalA, LocalB, LocalN, H),
8   Src ! [Rank, LocalInt].
9
10 getResult ( _From ) ->
11   %% Pode-se esperar na ordem para garantir resultados sempre iguais
12   %% recebe [From, Val] ->
13   receive [_, Val] -> %% Ou em qualquer ordem
14     Val
15   end.
```

Para compilar e rodar faça:

---

```
1 $ erlc trap.erl
2 $ erl -noshell -s trap main A B N P
```

---

- O código completo está disponível em:  
[http://professor.ufabc.edu.br/~e.francesquini/2019.q1.pp/files/codigo/trap\\_atores.html](http://professor.ufabc.edu.br/~e.francesquini/2019.q1.pp/files/codigo/trap_atores.html)

## Conclusão

---

- Acabou a mamata: se é preciso melhor desempenho, é preciso programar concorrentemente
- Aplicações precisam ser adaptadas. Quase nenhuma atualmente é preparada para isso.
- Programação baseada em estado compartilhado é difícil, propensa a erros, complicadíssima de se depurar, ...
- Existem modelos alternativos como
  - ▶ Concorrência por passagem de mensagem
  - ▶ Memória transacional