Modelo de computación BSP

Programación paralela y distribuida

Fernando Pérez Costoya

Bulk Synchronous Parallel (Valiant1990)

- Modelo de computación planteado como la
  - Arquitectura von Neumann para sistemas paralelos
  - Puente entre diseñadores HW y SW
    - HW diseñado para que dé soporte al modelo
      - Adecuado para sistemas con memoria compartida y distribuida
    - SW diseñado para que ejecute sobre el modelo
- Impacto limitado;retomado actual. (Apache Hama)
- Elementos del modelo:
  - Componentes con capacidad de procesamiento
  - Componente de comunicación (*router*)
  - Componente de sincronización (tipo barrera)

Modelo de ejecución de BSP

- Síncrono organizado como secuencia *supersteps*

- En *superstep* un componente de procesamiento:
  - Recibe mensajes de otros componentes
  - Realiza procesamiento local
  - Puede enviar mensajes a otros componentes proces.
  - Sincronización tipo barrera al final del *superstep*

Ciclo ejecución BSP (wikipedia)

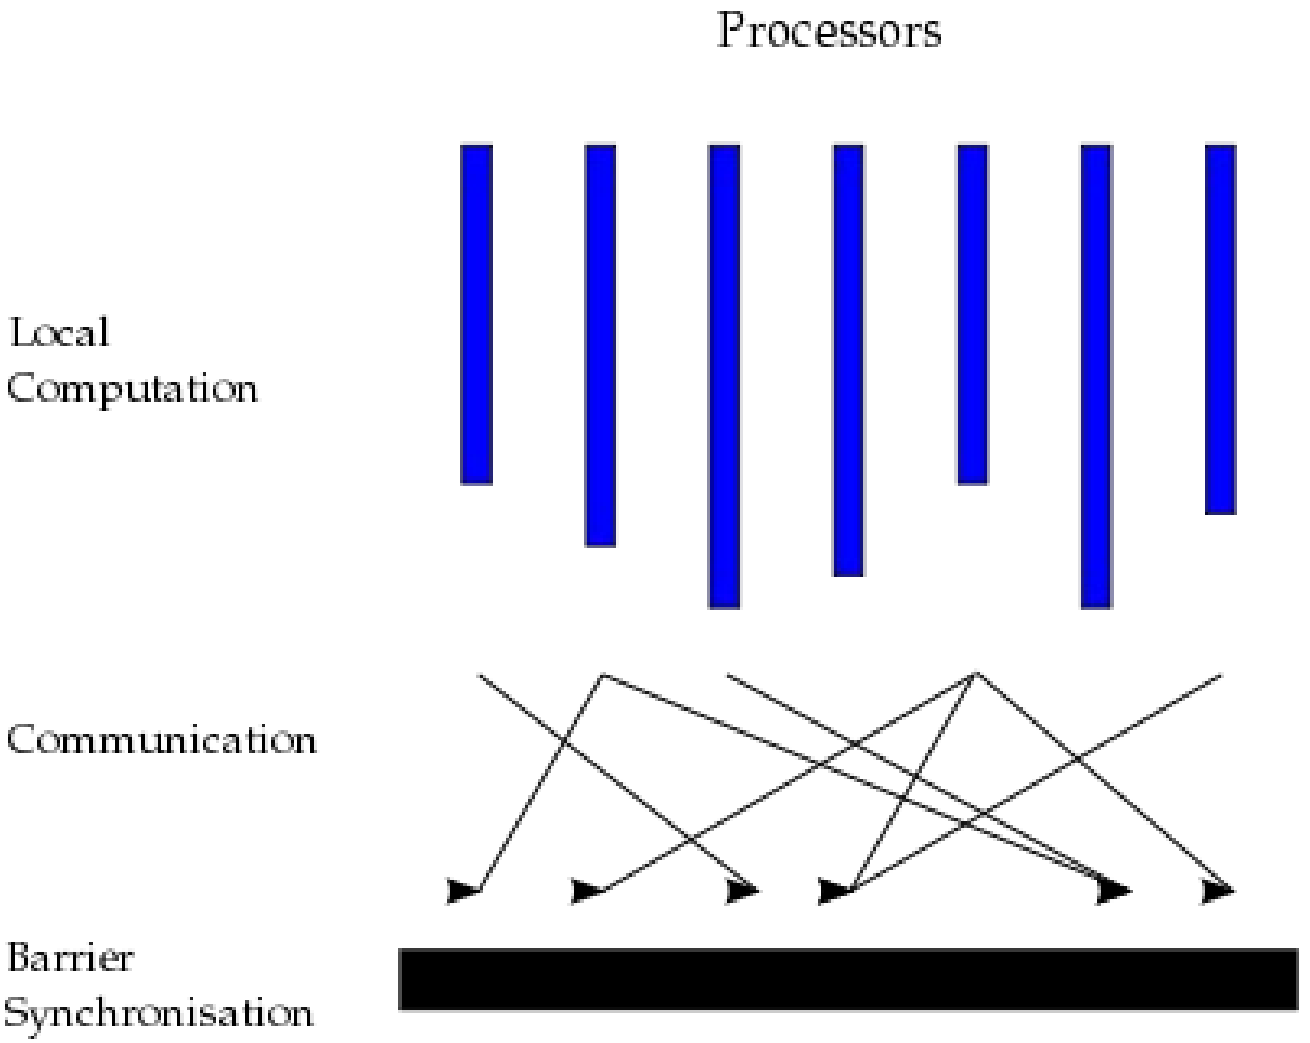

Modelos programación para grafos

Pregel

Programación paralela y distribuida

Fernando Pérez Costoya

Procesamiento de grafos

- Necesidad de procesar grafos de gran escala
  - Internet, redes sociales, rutas, etc.
    - Aplicación de algoritmos clásicos de grafos
  - Requieren sistemas paralelos/distribuidos
- ¿Modelo programación/*framework*/implementación que oculte sincro,comun,planificación,tolerancia..?
  - ¿MapReduce?
    - Programación no intuitiva
    - Ineficiencia: grafo viaja continuamente entre los nodos
  - Propuesta de Google: Pregel (2010)
    - Basado en BSP; Apache Giraph: versión de libre distribución

Pregel: modelo de programación

- Grafo dirigido tal que cada vértice tiene:
  - ID único; Valor asociado modificable
  - Conjunto de aristas salientes
    - Cada arista: valor asociado + vértice destino
  - Una función asociada (la misma para todos)
- Ejecución de un trabajo Pregel
  - Entrada → Grafo; Salida → Grafo (con la solución)
  - Secuencia de *supersteps*
    - Inicialmente todos los vértices activos
    - Fin de computación cuanto todos los vértices inactivos
      - Recepción de mensaje reactiva vértice

Evolución del estado de un vértice

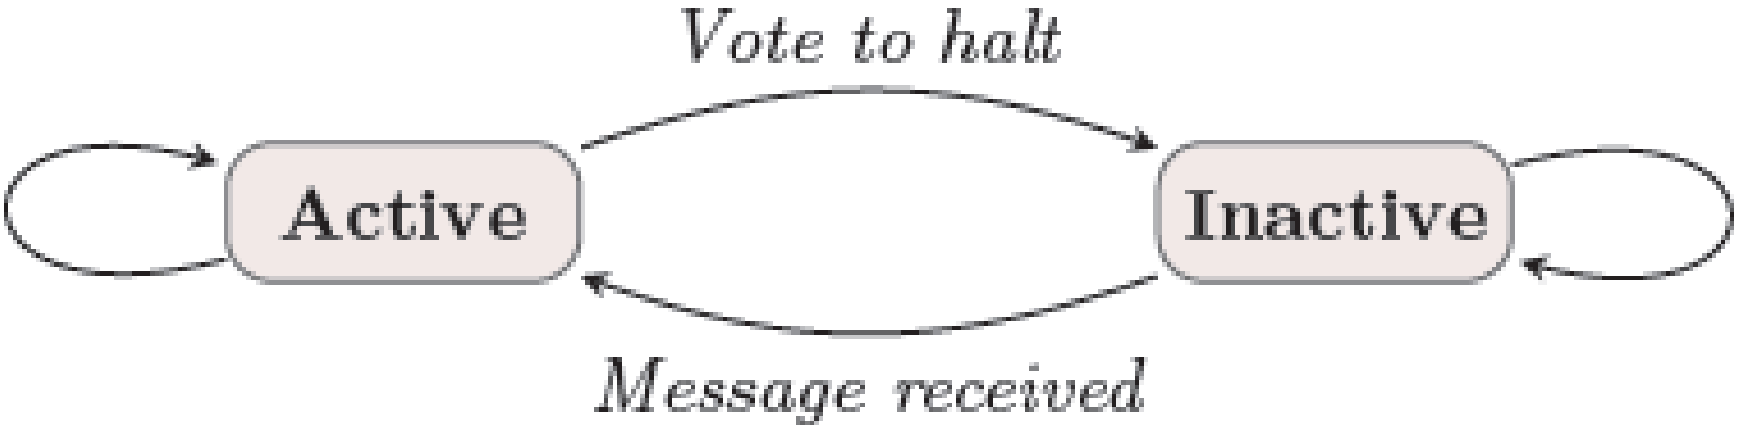

Ejecución de un *superstep*

- Ejecuta en paralelo la función sobre cada vértice
  - Esa función implementa la lógica del algoritmo
- La ejecución de la función en un vértice V puede:
  - Recibir mensajes enviados a V en *superstep* previo
  - Modificar valor del vértice y de las aristas salientes
  - Enviar mensajes a otros vértices
    - Conectados a V o a cualquiera si conoce su ID
    - Los mensajes se recibirán en siguiente *superstep*
  - Modificar la topología del grafo
    - Añadir/eliminar vértices y aristas

Ejemplo de cálculo del máximo

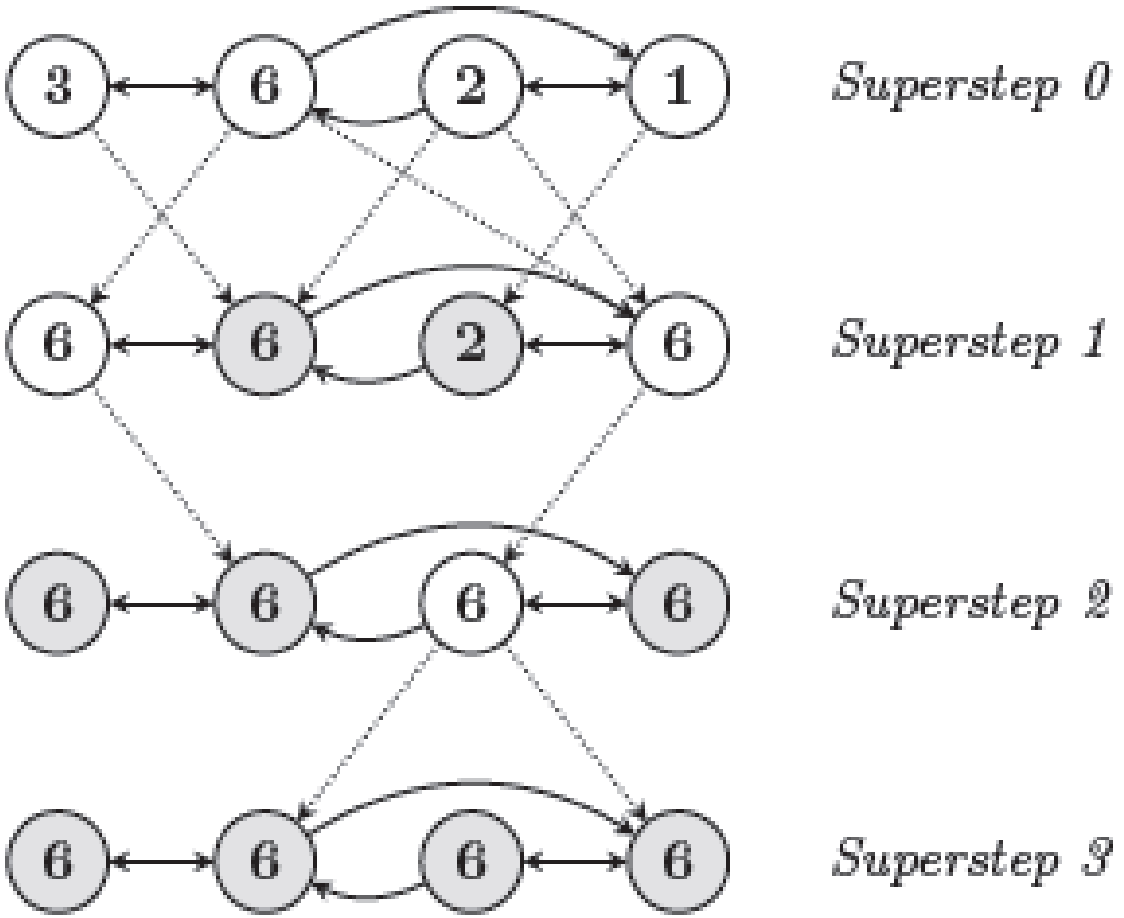

API en C++

- *Compute*: función de vértices
- *GetValue*|*MutableValue*:obtiene/cambia valor vértice
- *GetOutEdgeIterator*:inspecciona/cambia aristas sal.
- *SendMessageTo*:envío fiable pero no garantía orden
- *VoteToHalt*: nodo se hace inactivo
- Componentes adicionales:
  - *Combiners*: combinan mensajes destinados a mismo V
  - *Aggregators*: cada vértice puede provee valor a *aggreg*.
    - Sistema agrega valores y los deja disponibles en sig. superstep
- Mutaciones pueden causar conflictos
- E/S: formatos y soportes configurables

Clase Vértice

```
template <typename VertexValue,
          typename EdgeValue,
          typename MessageValue>
class Vertex {
 public:
  virtual void Compute(MessageIterator* msgs) = 0;

  const string& vertex_id() const;
  int64 superstep() const;

  const VertexValue& GetValue();
  VertexValue* MutableValue();
  OutEdgeIterator GetOutEdgeIterator();

  void SendMessageTo(const string& dest_vertex,
                     const MessageValue& message);
  void VoteToHalt();
};
```

Implementación

- **M**aestro-**T**rabajadores; Pasos ejecución trabajo:
  - **M** determina particiones en grafo y las asigna a **T**
    - Por defecto, *hash(ID vértice)*; puede redefinirlo la aplicación
  - **M** determina particiones en entrada y asigna a **T**
    - **T** lee partición; se queda con sus vértices y reenvía otros
    - Fin de la entrada → todos los vértices activos
  - **M** indica a todo **T** inicio *superstep*
    - **T** ejecuta función para cada uno de sus vértices
      - Entregando a cada vértice mensajes recibidos en *superstep* previo
      - Recoge mensajes enviados y transmite empaquetados asíncronamente
    - **T** señala a **M** fin de *superstep* especificando nº vértices activos
  - **M** espera respuesta de todos los **T** (barrera)
    - Si nº total activos=0→ Fin: **M** solicita a **T** volcado de resultados

Tolerancia a fallos

- *Checkpoint* (CHK) en almacenamiento persistente
  - Valores de vértices, aristas y mensajes entrantes
- Al inicio de un *superstep* **M** solicita CHK a los **T**
- Caída de **T**
  - Reasigna particiones de **T** a otros trabajadores
  - **M** solicita a todos los **T** que recuperen último CHK
    - Y vuelvan a ejecutar desde ese *superstep*
      - Trabajo repetido por parte de trabajadores que no se han caído
- Recuperación confinada bajo desarrollo (en 2010)
  - CHK de mensajes salientes
  - Reduce gasto innecesario recursos: sólo nodos caídos

Aplicaciones: *PageRank*

```
class PageRankVertex
    : public Vertex<double, void, double> {
 public:
  virtual void Compute(MessageIterator* msgs) {
    if (superstep() >= 1) {
      double sum = 0;
      for (; !msgs->Done(); msgs->Next())
        sum += msgs->Value();
      *MutableValue() =
          0.15 / NumVertices() + 0.85 * sum;
    }

    if (superstep() < 30) {
      const int64 n = GetOutEdgeIterator().size();
      SendMessageToAllNeighbors(GetValue() / n);
    } else {
      VoteToHalt();
    }
  }
};
```

Aplicaciones: *Shortest Path*

```
class ShortestPathVertex
    : public Vertex<int, int, int> {
  void Compute(MessageIterator* msgs) {
    int mindist = IsSource(vertex_id()) ? 0 : INF;
    for (; !msgs->Done(); msgs->Next())
      mindist = min(mindist, msgs->Value());
    if (mindist < GetValue()) {
      *MutableValue() = mindist;
      OutEdgeIterator iter = GetOutEdgeIterator();
      for (; !iter.Done(); iter.Next())
        SendMessageTo(iter.Target(),
                      mindist + iter.GetValue());
    }
    VoteToHalt();
  }
};
```

Combiner para *Shortest Path*

```
class MinIntCombiner : public Combiner<int> {
  virtual void Combine(MessageIterator* msgs) {
    int mindist = INF;
    for (; !msgs->Done(); msgs->Next())
      mindist = min(mindist, msgs->Value());
    Output("combined_source", mindist);
  }
};
```