東邦大学

生命（いのち）の科学で未来をつなぐ

メモリ階層とキャッシュ

メモリ階層の考え方

東邦大学

メモリ階層

メモリ素子

高速だが小容量

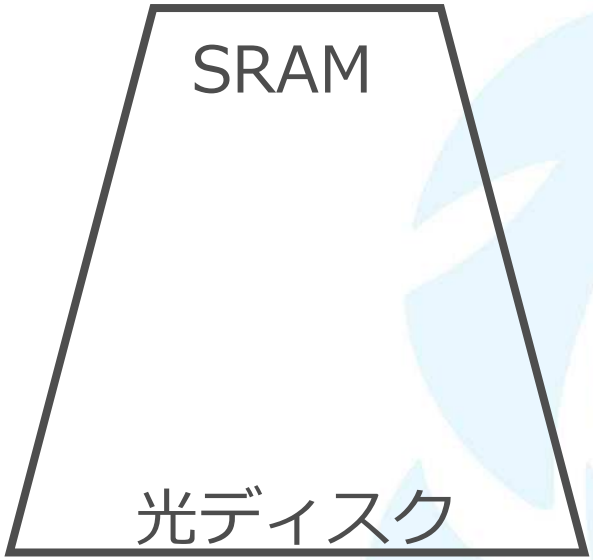

低速だが大容量

メモリ階層

メモリ素子

高速だが小容量

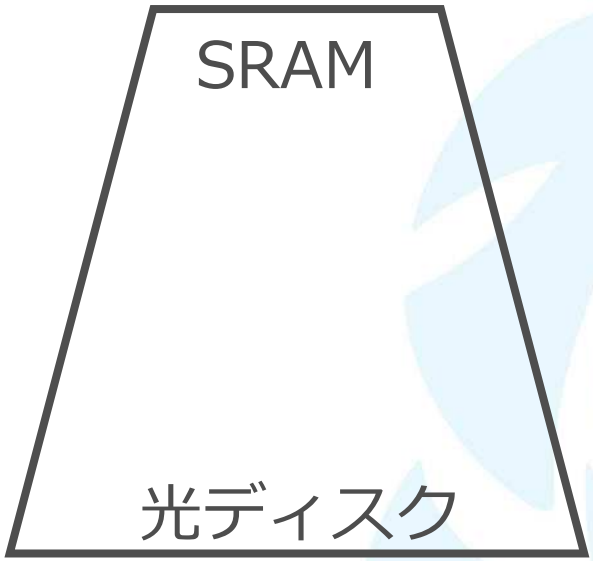

低速だが大容量

適材適所で使う

東邦大学

メモリ階層

メモリ素子

高速だが小容量

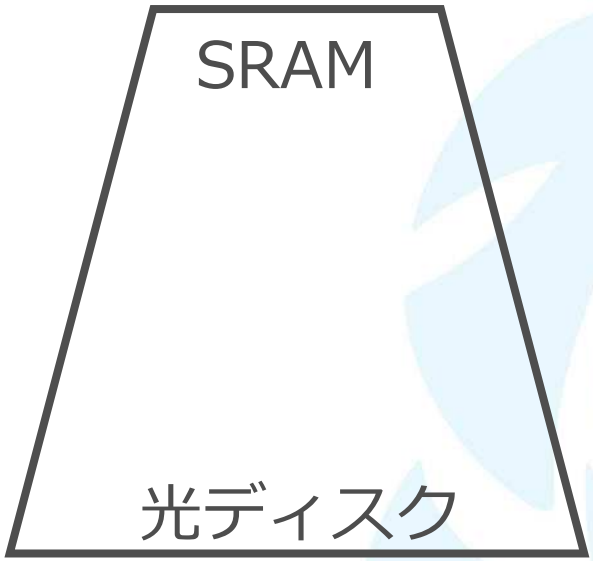

低速だが大容量

適材適所で使う

組合せて使う

東邦大学

メモリ階層

高速だが小容量

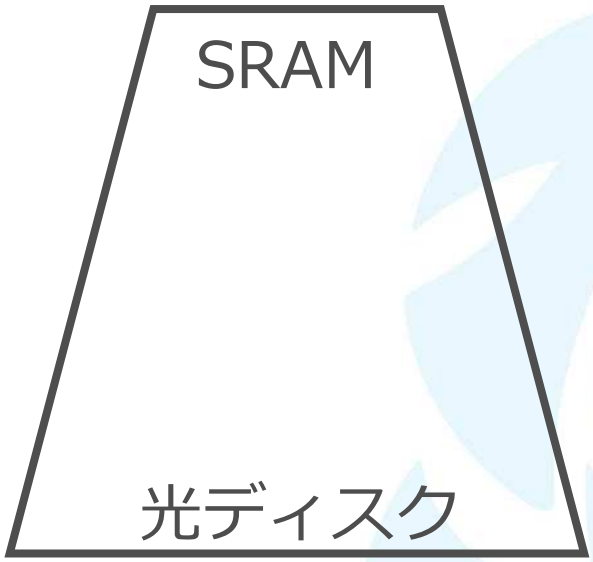

低速だが大容量

適材適所

普段使い用

CPUから頻繁にアクセス

CPU速度で返答

少量で我慢

保存用

大量に保存

滅多に見ない

東邦大学

メモリ階層

高速だが小容量

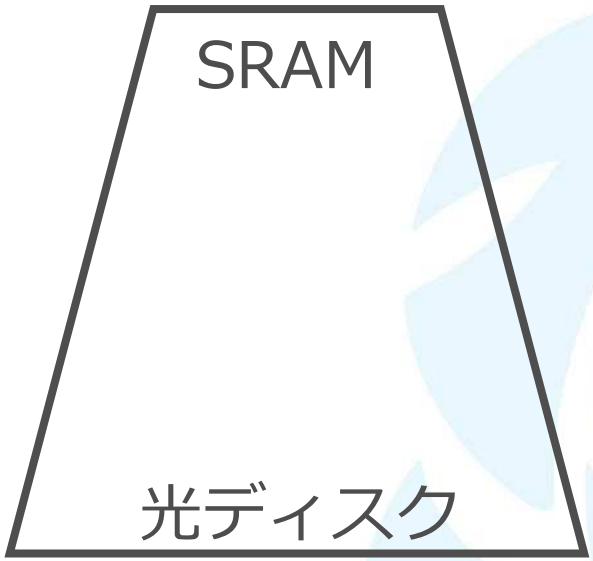

低速だが大容量

適材適所

普段使い用
- レジスタ
- キャッシュ(後述)
- 主記憶
  - ⇒命令毎アクセス

保存用
- ファイル
  - ⇒保存用

東邦大学

メモリ階層

組合せて使う

高速だが小容量

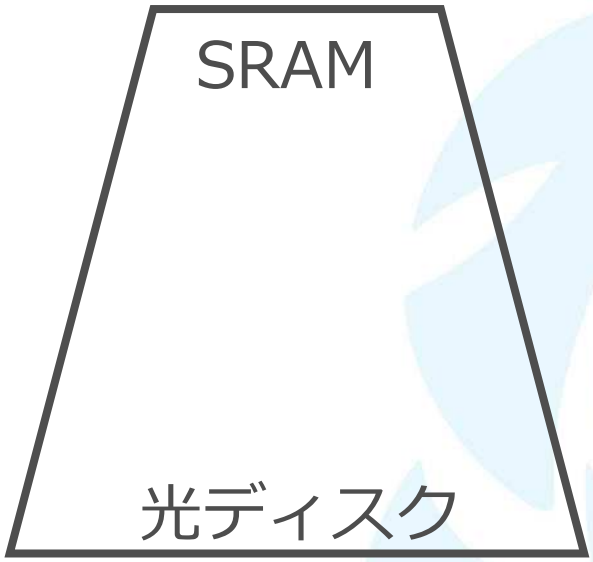

低速だが大容量

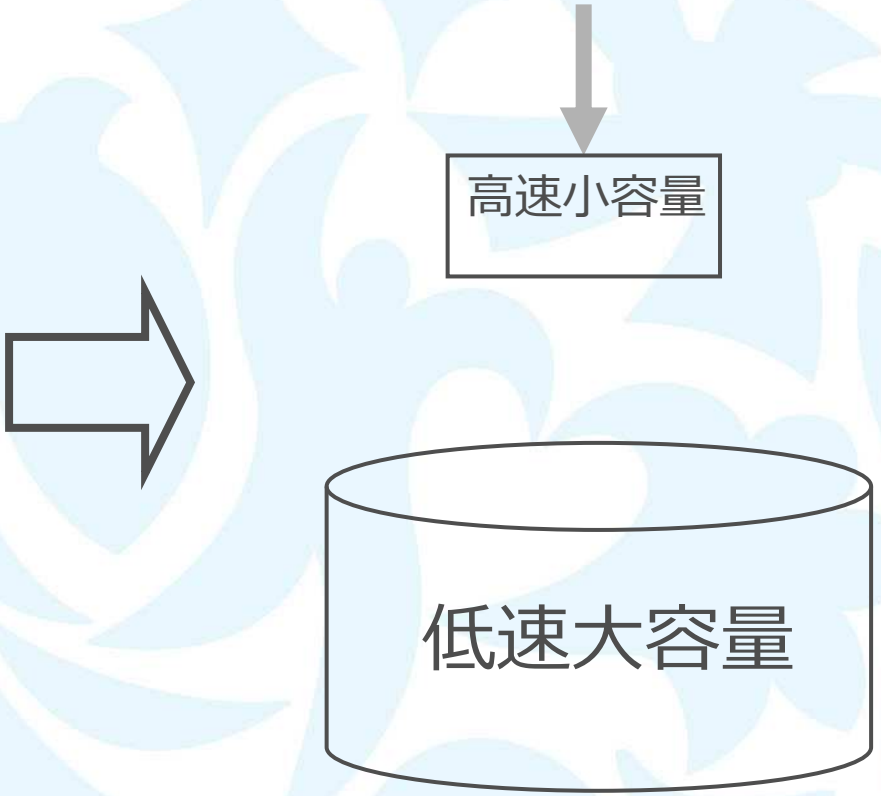

東邦大学

メモリ階層

組合せて使う

高速だが小容量

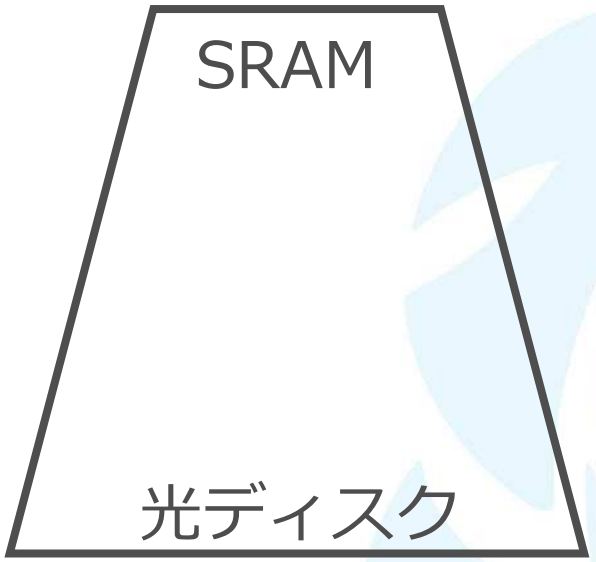

低速だが大容量

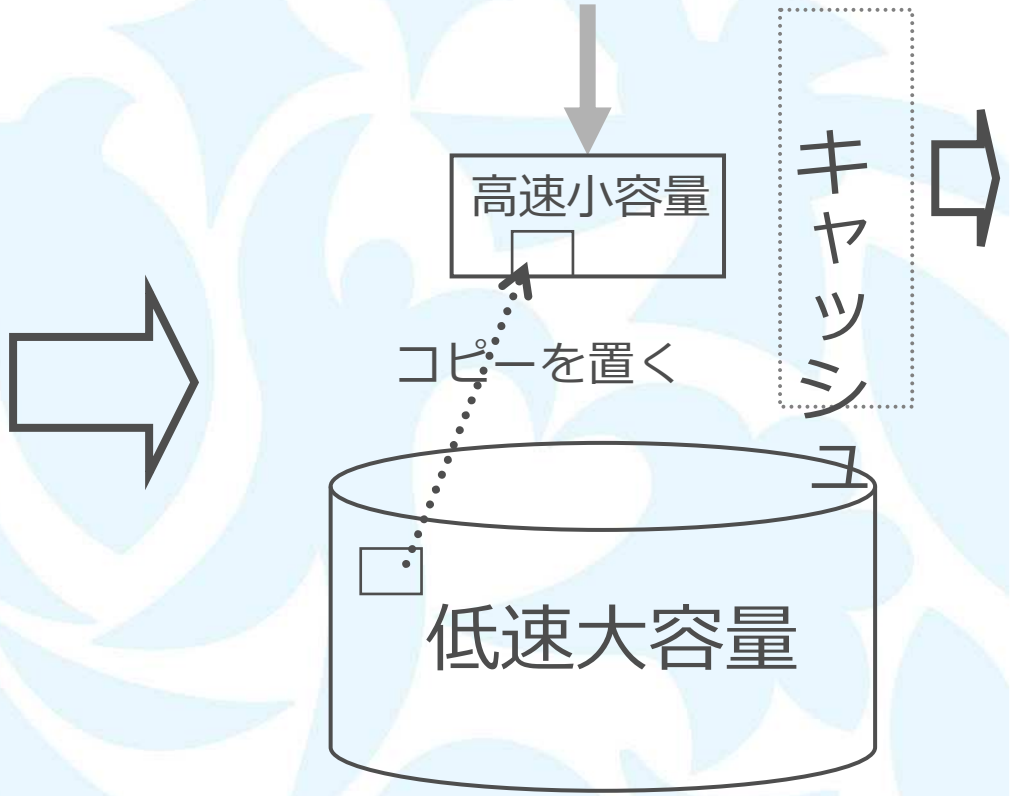

東邦大学

キャッシュ

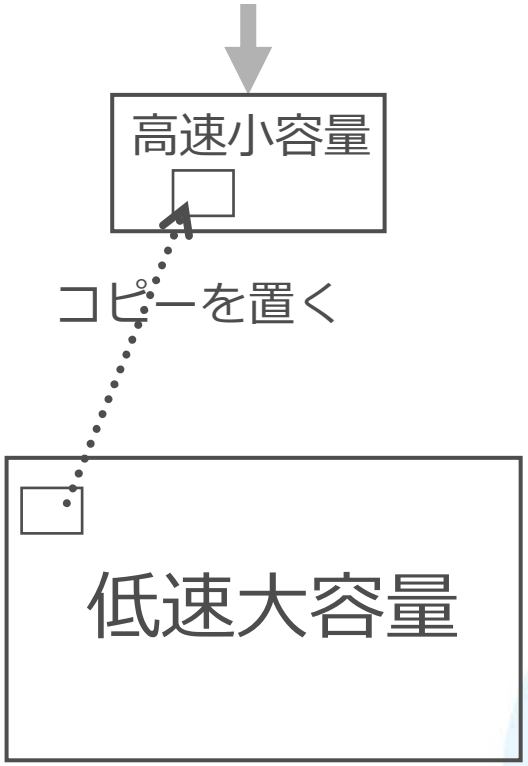

考え方

キャッシュ

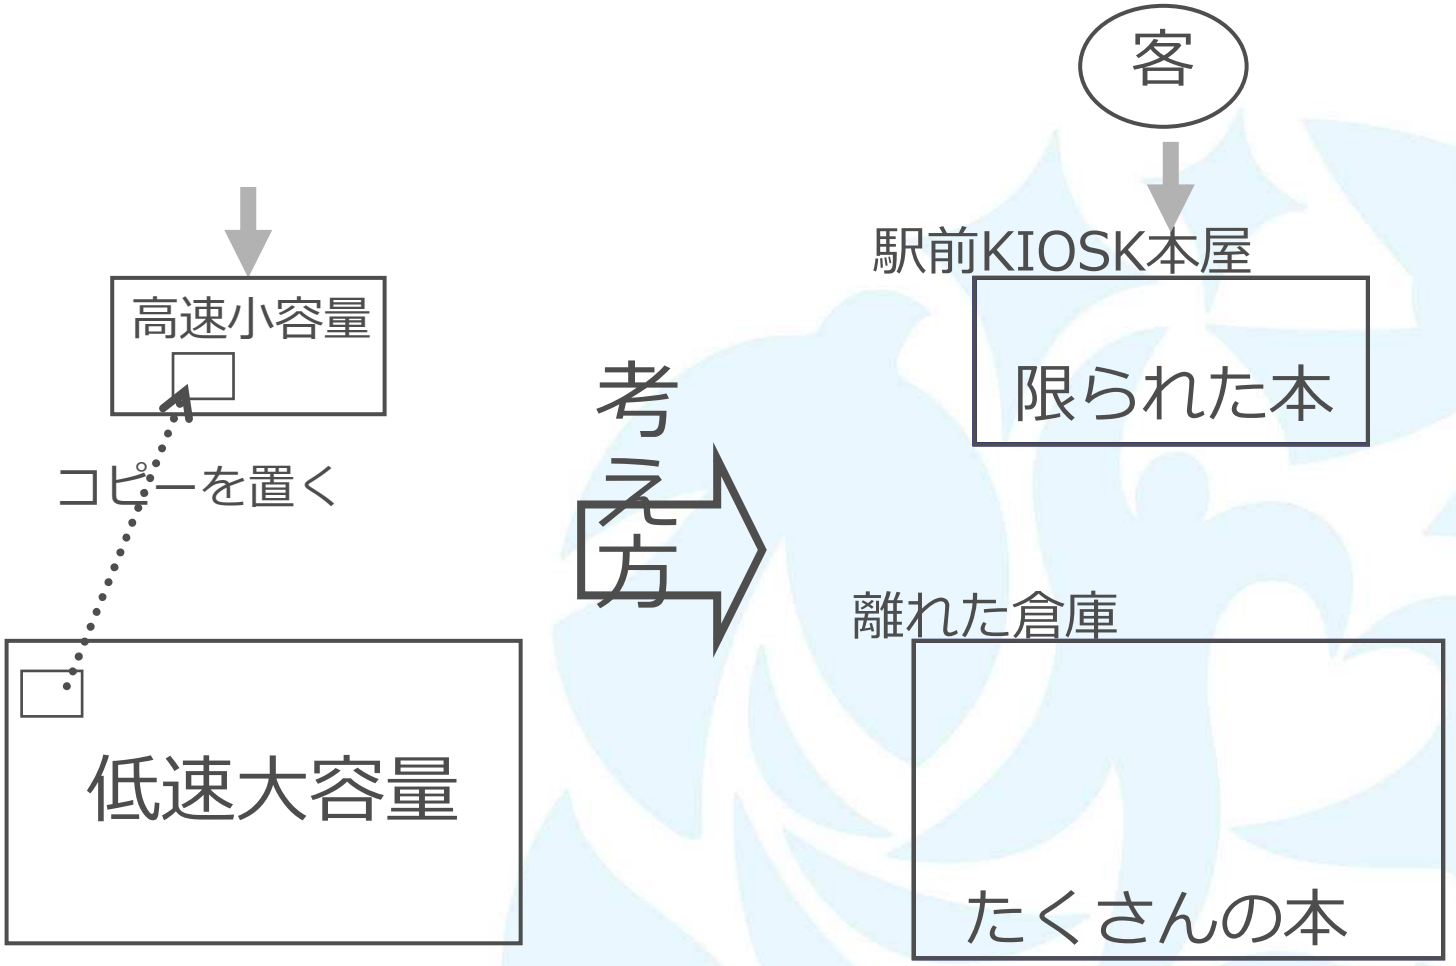

キャッシュ

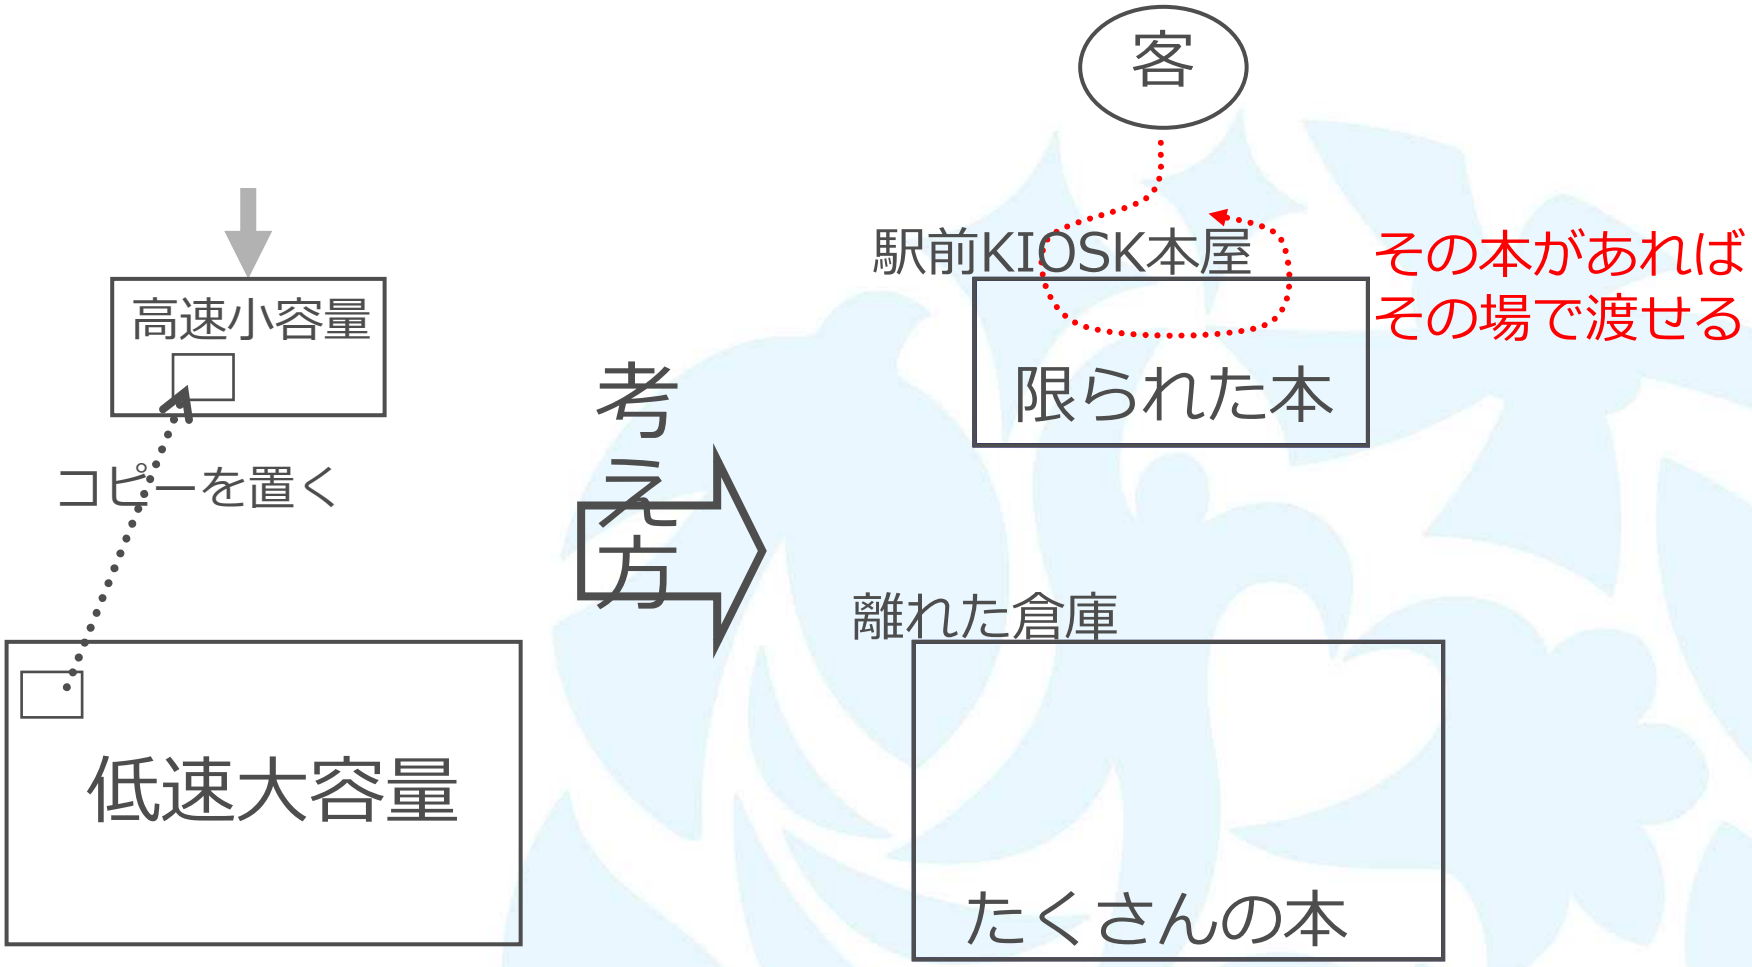
客
駅前KIOSK本屋
限られた本
その本があれば
その場で渡せる
考え方
高速小容量
コピーを置く
低速大容量
離れた倉庫
たくさんの本

東邦大学

キャッシュ

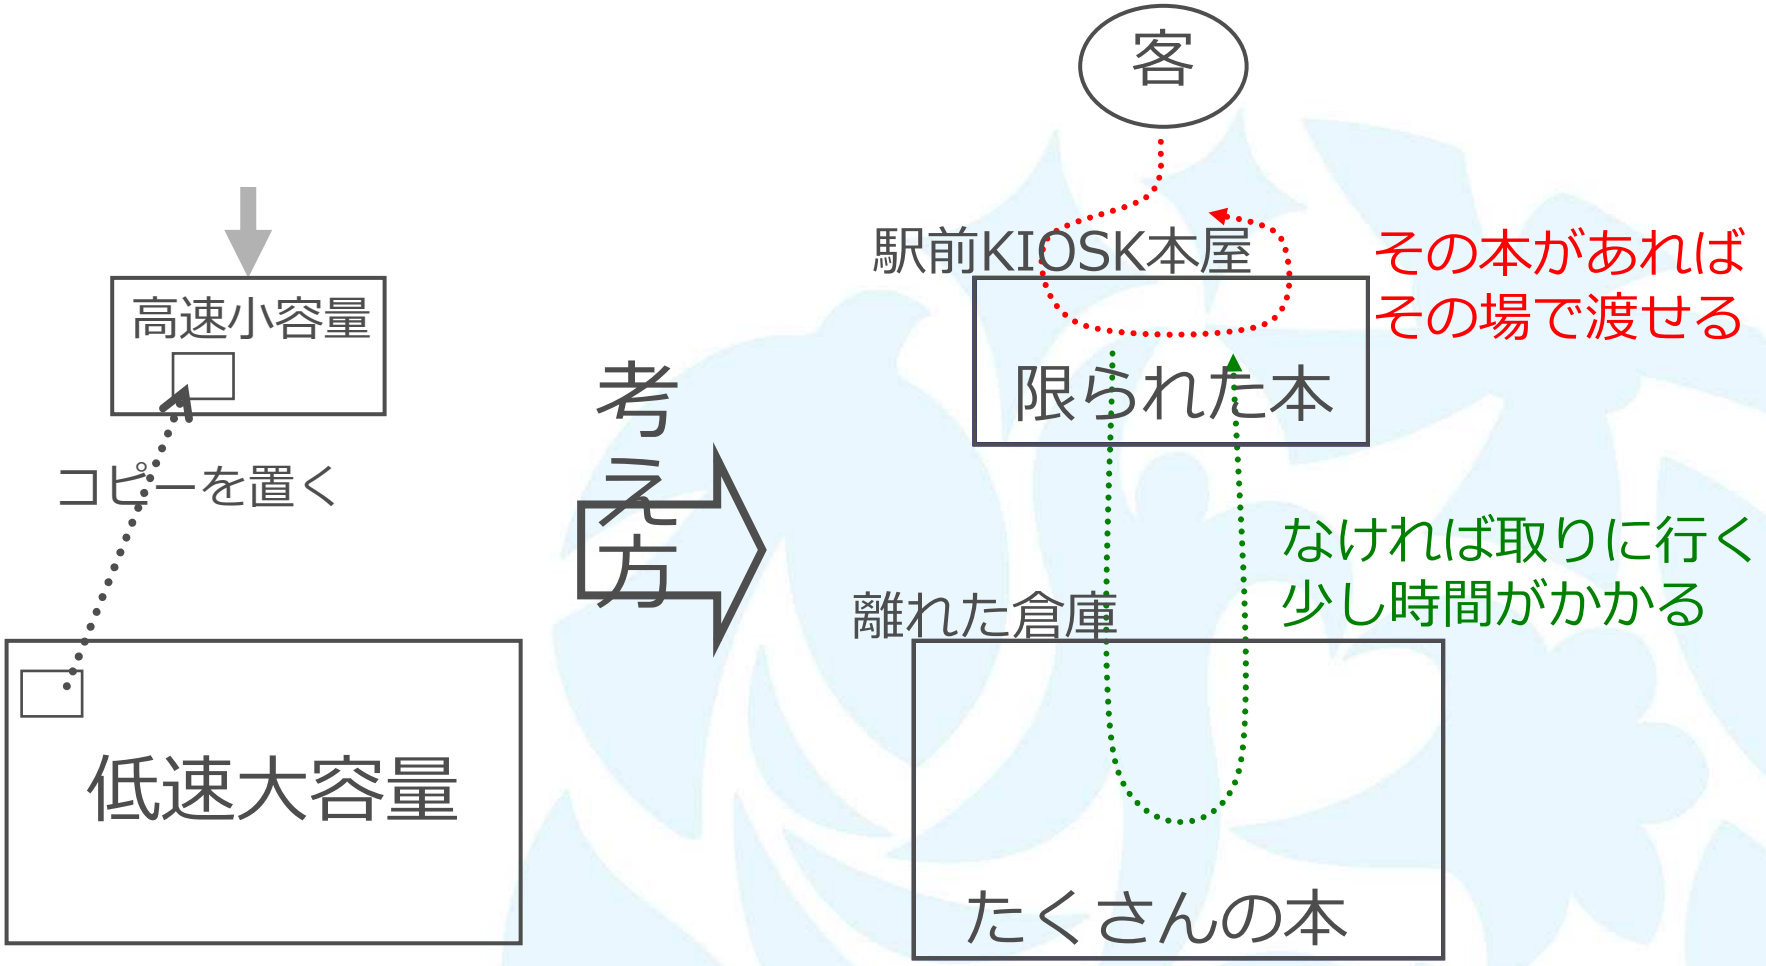
客
駅前KIOSK本屋
その本があれば
その場で渡せる
限られた本
高速小容量
コピーを置く
考え方
なければ取りに行く
少し時間がかかる
離れた倉庫
低速大容量
たくさんの本

東邦大学

キャッシュ

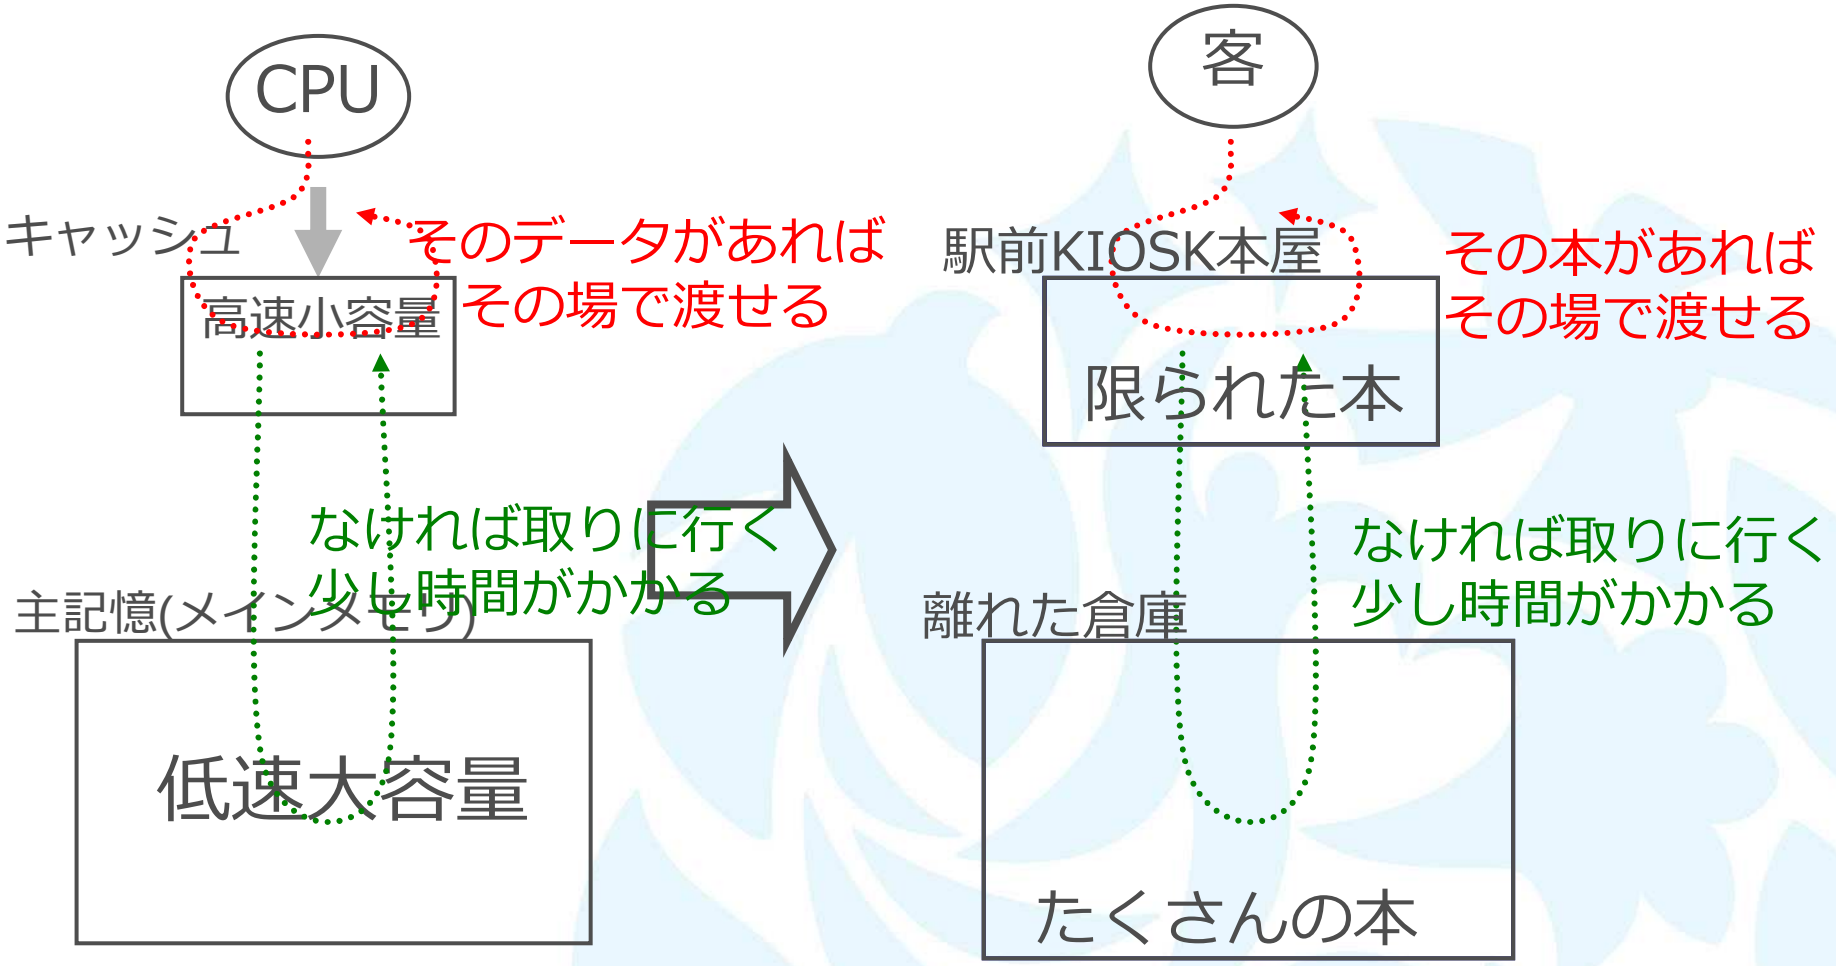
CPU
キャッシュ
そのデータがあれば
その場で渡せる
高速小容量
なければ取りに行く
少し時間がかかる
主記憶(メインメモリ)
低速大容量
客
駅前KIOSK本屋
その本があれば
その場で渡せる
限られた本
なければ取りに行く
少し時間がかかる
離れた倉庫
たくさんの本

東邦大学

整理すると

CPU ⇒ キャッシュ ⇒ 主記憶

キャッシュには、主記憶の一部のコピー

CPUがキャッシュへ取りに来て

　あったらその場で返す　⇒　速い

　なかったら主記憶から持ってきて渡す

　　⇒　時間がかかる

キャッシュの仕組みのテストです

東邦大学

整理すると

CPU ⇒ キャッシュ ⇒ 主記憶

キャッシュには、主記憶の一部のコピー

CPUがキャッシュへ取りに来て

　あったらその場で返す　⇒　速い

　なかったら主記憶から持ってきて渡す

　　⇒　時間がかかる

キャッシュは

[ ]と[ ]の間にあり

[ ]よりはずっと容量が[ ]

主記憶の一部を覚えており

[ ]がデータを要求したとき

そのデータを持っていれば[ ]

無ければ[ ]

キャッシュは

CPUと主記憶の間にあり

主記憶よりはずっと容量が小さい

主記憶の一部を覚えており

[　　]がデータを要求したとき

そのデータを持っていれば[　　]

無ければ[　　　　　　　　　　]

キャッシュは
　CPUと主記憶の間にあり
　主記憶よりはずっと容量が小さい
主記憶の一部を覚えており
　CPUがデータを要求したとき
　そのデータを持っていれば返し
　無ければ主記憶に取りにいく

キャッシュの動作がわかりましたか？

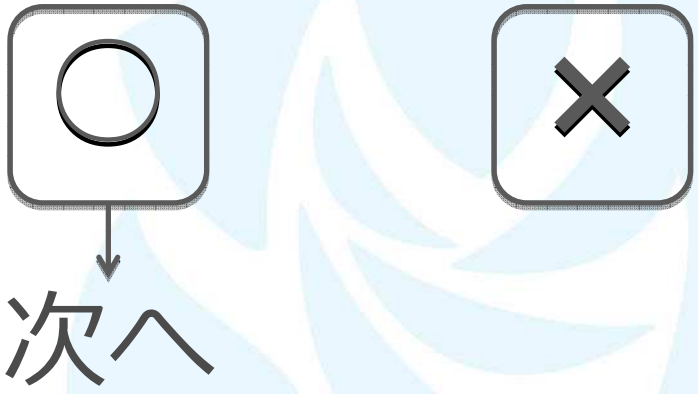

東邦大学

なぜこれがうまくいくのか？

東邦大学

なぜこれがうまくいくのか？

ほとんどの客がKIOSKで済めばいい

東邦大学

なぜこれがうまくいくのか？

ほとんどの客がKIOSKで済めばいい

ほとんどの客が買う本が限られて(売れ筋)いて
その本がKIOSKに置いてあればよい

東邦大学

もう少しきちんと考えてみよう

東邦大学

アクセス時間のモデル

アクセス時間のモデル

KIOSKにあったらその場で返す
　なかったら主記憶から持ってきて渡す

アクセス時間のモデル

KIOSKにあったらその場で返す
　なかったら主記憶から持ってきて渡す

二者択一　どちらか一方が起こる

東邦大学

アクセス時間のモデル

KIOSKにあったらその場で返す
　なかったら主記憶から持ってきて渡す

二者択一　どちらか一方が起こる

かかる時間の期待値（予測値）は

アクセス時間のモデル

KIOSKにあったらその場で返す
　なかったら主記憶から持ってきて渡す

二者択一　どちらか一方が起こる

かかる時間の期待値（予測値）は
　(KIOSKで済む場合の時間)×(済む確率)

東邦大学

アクセス時間のモデル

KIOSKにあったらその場で返す
　なかったら主記憶から持ってきて渡す

二者択一　どちらか一方が起こる

かかる時間の期待値（予測値）は

　(KIOSKで済む場合の時間)×(済む確率)
＋(済まない場合の時間)×(済まない確率)

アクセス時間のモデル

かかる時間の期待値（予測値）は

(KIOSKで済む場合の時間)×(済む確率)
＋(済まない場合の時間)×(済まない確率)

アクセス時間のモデル

かかる時間の期待値（予測値）は

(KIOSKで済む場合の時間)×(済む確率)
＋(済まない場合の時間)×(済まない確率)

もし

	かかる時間	確率
KIOSKで済む場合	1	0.5
済まない場合	10	0.5

アクセス時間のモデル

かかる時間の期待値（予測値）は

(KIOSKで済む場合の時間)×(済む確率)
＋(済まない場合の時間)×(済まない確率)

もし

	かかる時間	確率
KIOSKで済む場合	1	0.5
済まない場合	10	0.5

⇨

期待値
＝ 1 × 0.5
＋10 × 0.5
＝ 5.5

アクセス時間のモデル

かかる時間の期待値（予測値）は

(KIOSKで済む場合の時間)×(済む確率)
＋(済まない場合の時間)×(済まない確率)

もし

	かかる時間	確率
KIOSKで済む場合	1	0.5
済まない場合	10	0.5

⇨ 期待値
＝ 1 × 0.5
＋10 × 0.5
＝ 5.5　速くない

アクセス時間のモデル

かかる時間の期待値（予測値）は

(KIOSKで済む場合の時間)×(済む確率)
＋(済まない場合の時間)×(済まない確率)

もし

	かかる時間	確率
KIOSKで済む場合	1	0.9
済まない場合	10	0.1

⇨ ほとんどKIOSKで済むとどうなるか

アクセス時間のモデル

かかる時間の期待値（予測値）は

(KIOSKで済む場合の時間)×(済む確率)
＋(済まない場合の時間)×(済まない確率)

もし

	かかる時間	確率
KIOSKで済む場合	1	0.9
済まない場合	10	0.1

期待値
＝ 1 × 0.9
＋10 × 0.1
＝ 1.9　2倍ぐらい

東邦大学

アクセス時間のモデル

かかる時間の期待値（予測値）は

(KIOSKで済む場合の時間)×(済む確率)
＋(済まない場合の時間)×(済まない確率)

もし

	かかる時間	確率
KIOSKで済む場合	1	0.99
済まない場合	10	0.01

⇨ もっとほとんどKIOSKで済むとどうなるか

アクセス時間のモデル

かかる時間の期待値（予測値）は

(KIOSKで済む場合の時間)×(済む確率)
＋(済まない場合の時間)×(済まない確率)

もし

	かかる時間	確率
KIOSKで済む場合	1	0.99
済まない場合	10	0.01

期待値
＝ 1 × 0.99
＋10 × 0.01
＝ 1.09 1.1倍弱

東邦大学

アクセス時間のモデル

まとめると、時間比率が 1 対 10 のとき

KIOSKで済む場合の確率	かかる時間 (KIOSKだけの時間との比)
0.5	
0.9	
0.99	

アクセス時間のモデル

まとめると、時間比率が 1 対 10 のとき

KIOSKで済む場合の確率	かかる時間 (KIOSKだけの時間との比)
0.5	5.5
0.9	1.9
0.99	1.09

アクセス時間のモデル

まとめると、時間比率が 1 対 10 のとき

KIOSKで済む場合の確率	かかる時間 (KIOSKだけの時間との比)
0.5	5.5
0.9	1.9
0.99	1.09

KIOSKだけで済む場合の確率(ヒット率)が十分に大きければ
(ここでは0.99)
倉庫に取り行くことがあっても、あまり時間は増えない (1.09)

東邦大学

アクセス時間のまとめ

キャッシュシステム全体のアクセス時間は

＋ × ×

キャッシュにデータがある確率(ヒット率)が　　とき初めて、
全体の時間が

アクセス時間のまとめ

キャッシュシステム全体のアクセス時間は

(キャッシュアクセス時間) × (キャッシュにデータがある確率)

＋ [ ] × [ ]

キャッシュにデータがある確率(ヒット率)が [ ] とき初めて、

全体の時間が [ ]

アクセス時間のまとめ

キャッシュシステム全体のアクセス時間は

(キャッシュアクセス時間) × (キャッシュにデータがある確率)

＋ (主記憶のアクセス時間) × (ないので主記憶に取りに行く確率)

キャッシュにデータがある確率(ヒット率)が　　とき初めて、

全体の時間が

アクセス時間のまとめ

キャッシュシステム全体のアクセス時間は

(キャッシュアクセス時間) × (キャッシュにデータがある確率)

＋ (主記憶のアクセス時間) × (ないので主記憶に取りに行く確率)

キャッシュにデータがある確率(ヒット率)が十分高いとき初めて、全体の時間がキャッシュに近づく

東邦大学

キャッシュシステムの
アクセス時間のモデルは
理解できましたか？

東邦大学

では、ヒット率はどのぐらい？

ヒット率＝CPUからのアクセスが
(手前の)キャッシュで済む確率

東邦大学

ヒット率（手前だけで済む確率）

決まった値があるわけではない
　メモリのアクセスの仕方に依存する

ヒット率（手前だけで済む確率）

決まった値があるわけではない

メモリのアクセスの仕方に依存する

同じ場所に繰り返してアクセスすれば

ヒット率（手前だけで済む確率）

決まった値があるわけではない

メモリのアクセスの仕方に依存する

同じ場所に繰り返してアクセスすれば

最初の1回は主記憶（倉庫）に取りに行くが

ヒット率（手前だけで済む確率）

決まった値があるわけではない

メモリのアクセスの仕方に依存する

同じ場所に繰り返してアクセスすれば

最初の1回は主記憶（倉庫）に取りに行くが

次からはキャッシュ（KIOSK）で済む

ヒット率（手前だけで済む確率）

決まった値があるわけではない

メモリのアクセスの仕方に依存する

同じ場所に繰り返してアクセスすれば

最初の1回は主記憶（倉庫）に取りに行くが

次からはキャッシュ（KIOSK）で済む

たとえば100回繰り返してアクセスすれば

最初の1回は主記憶（倉庫）に取りに行くが

99回はキャッシュ（KIOSK）で済む

⇒　ヒット率は99/100＝0.99

ヒット率（キャッシュで済む確率）

同じ場所に繰り返してアクセスすれば
最初の1回は主記憶（倉庫）に取りに行くが
次からはキャッシュ（KIOSK）で済む

実は、持ってくる単位は1データ分ではなくて
大きいブロック（たとえば16データ分）なので
⇒　連続したアドレスにアクセスするなら
主記憶（倉庫）には16回中1回のみ

ヒット率（キャッシュで済む確率）

同じ場所に繰り返してアクセスすれば
最初の1回は主記憶（倉庫）に取りに行くが
次からはキャッシュ（KIOSK）で済む

実は、持ってくる単位は1データ分ではなくて
大きいブロック（たとえば16データ分）なので
⇒　連続したアドレスにアクセスするなら
主記憶（倉庫）には16回中1回のみ

連続した命令読出しは
連続したアドレス

ループを何度も回れば
命令もデータも同じアドレス

ヒット率（キャッシュで済む確率）

普通考えるより、同じようなアドレスを
繰り返しアクセスする確率が高い

ヒット率（キャッシュで済む確率）

普通考えるより、同じようなアドレスを
繰り返しアクセスする確率が高い

⇒　「アクセスの局所性」

ヒット率（キャッシュで済む確率）

普通考えるより、同じようなアドレスを
　繰り返しアクセスする確率が高い

　⇒　「アクセスの局所性」

実際のプログラムで測定してみると
　かなり局所性が高いことが分かっている

ヒット率（キャッシュで済む確率）

普通考えるより、同じようなアドレスを
繰り返しアクセスする確率が高い

⇒　「アクセスの局所性」

実際のプログラムで測定してみると
かなり局所性が高いことが分かっている

⇒　キャッシュによって十分速くなる

東邦大学

ヒット率の性質のまとめ

ヒット率は
　普通考える(ランダム)より
理由は「アクセスの」が
　成り立つことが多いからである
キャッシュはブロック単位で転送され
　次の命令読出しやデータアクセスが
　同じブロック内に入る確率が

ヒット率の性質のまとめ

ヒット率は
　普通考える(ランダム)より高い
理由は「アクセスの　　」が
　成り立つことが多いからである
キャッシュはブロック単位で転送され
　次の命令読出しやデータアクセスが
　同じブロック内に入る確率が　　

ヒット率の性質のまとめ

ヒット率は
　普通考える(ランダム)より高い
理由は「アクセスの局所性」が
　成り立つことが多いからである
キャッシュはブロック単位で転送され
　次の命令読出しやデータアクセスが
　同じブロック内に入る確率が

ヒット率の性質のまとめ

ヒット率は
　普通考える(ランダム)より高い
理由は「アクセスの局所性」が
　成り立つことが多いからである
キャッシュはブロック単位で転送され
　次の命令読出しやデータアクセスが
　同じブロック内に入る確率が高い

ヒット率の性質について
理解できましたか？

東邦大学

置き換えアルゴリズム

キャッシュが一杯のとき
どうしよう

東邦大学

置き換えの必要性

置き換えの必要性

いつ？

置き換えの必要性

いつ？

新しくブロックを拾ってきたのに
置く場所が無いとき

置き換えの必要性

いつ？

新しくブロックを拾ってきたのに
置く場所が無いとき

なぜ置く場所が無い？

⇒本当に満杯で、空きが無い？

置き換えの必要性

いつ？

新しくブロックを拾ってきたのに
置く場所が無いとき

なぜ置く場所が無い？

⇒本当に満杯で、空きが無い、か

⇒置き方のルール上
ぶつかって置けない

置き方のルール(マッピング方式)は？

空いている所どこでも

決まった所（番号割当）

駐車場のイメージ

空いている所どこでも

- 場所の効率はいい（いっぱいまで使える）
- 入れるとき簡単（空いている所どこでも）

決まった所（番号割当）

駐車場のイメージ

空いている所どこでも

- 場所の効率はいい（いっぱいまで使える）
- 入れるとき簡単（空いている所どこでも）
- 探すのが大変（場所番号が分からない）

決まった所（番号割当）

駐車場のイメージ

空いている所どこでも

場所の効率はいい（いっぱいまで使える）

入れるとき簡単（空いている所どこでも）

探すのが大変（場所番号が分からない）

決まった所 (ナンバー下2桁＝場所番号)

東邦大学

駐車場のイメージ

空いている所どこでも

- 場所の効率はいい（いっぱいまで使える）
- 入れるとき簡単（空いている所どこでも）
- 探すのが大変（場所番号が分からない）

決まった所 (ナンバー下2桁＝場所番号)

- 探すのは簡単（ナンバーからすぐ分かる）
- 入れるとき簡単（ナンバーから決まる）

東邦大学

駐車場のイメージ

空いている所どこでも

- 場所の効率はいい（いっぱいまで使える）
- 入れるとき簡単（空いている所どこでも）
- 探すのが大変（場所番号が分からない）

決まった所 (ナンバー下2桁＝場所番号)

- 探すのは簡単（ナンバーからすぐ分かる）
- 入れるとき簡単（ナンバーから決まる）
- 場所の効率悪い（他に空いていてもダメ）

東邦大学

キャッシュの置き方も同じ

空いている所どこでも（アソシアティブ方式）

- 場所の効率はいい（いっぱいまで使える）
- 入れるとき簡単（空いている所どこでも）
- 探すのが大変（場所番号が分からない）

決まった所(アドレス一部)(ダイレクトマップ方式)

- 探すのは簡単（アドレスからすぐ分かる）
- 入れるとき簡単（アドレスから決まる）
- 場所の効率悪い（他に空いていてもダメ）

というわけで折衷案

というわけで折衷案
セットアソシアティブ方式

行内の場所を選ぶのは
フルアソシアティブ方式

どの行を
選ぶかは
ダイレクト
マップ方式

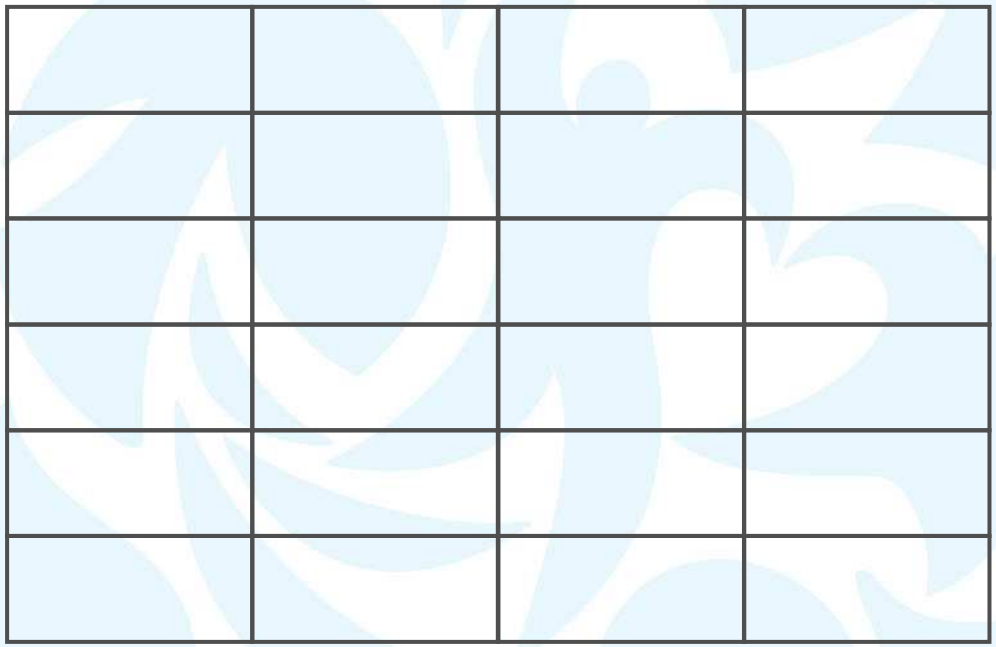

東邦大学

キャッシュの置き方(マッピング)のまとめ

方式

場所が決まる

方式

置ける

方式

両者の折衷案

キャッシュの置き方(マッピング)のまとめ

ダイレクトマップ方式

場所が決まる

方式

置ける

方式

両者の折衷案

キャッシュの置き方(マッピング)のまとめ

ダイレクトマップ方式

アドレスによって場所が決まる

[redacted]方式

[redacted]置ける

[redacted]方式

両者の折衷案

[redacted]

キャッシュの置き方(マッピング)のまとめ

ダイレクトマップ方式

アドレスによって場所が決まる

フルアソシアティブ方式

置ける

方式

両者の折衷案

キャッシュの置き方(マッピング)のまとめ

ダイレクトマップ方式

アドレスによって場所が決まる

フルアソシアティブ方式

任意の場所に置ける

方式

両者の折衷案

キャッシュの置き方(マッピング)のまとめ

ダイレクトマップ方式

アドレスによって場所が決まる

フルアソシアティブ方式

任意の場所に置ける

方式

両者の折衷案

キャッシュの置き方(マッピング)のまとめ

ダイレクトマップ方式

アドレスによって場所が決まる

フルアソシアティブ方式

任意の場所に置ける

セットアソシアティブ方式

両者の折衷案
ダイレクトマップで決めたブロックの中でフルアソシアティブ

東邦大学

キャッシュの置き方について
理解できましたか？

次へ

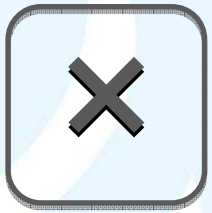

東邦大学