

マルチビットマップ表現による コミットメント制御

小寺 誠、横山 恭子、吉田 誠
(沖電気工業株式会社)

1. まえがき

ローカルネットワークの普及とワークステーションに発展により、これらを組み合せた分散処理システムの開発が盛んになってきている。このようなシステムでは、リモートからのファイルアクセス要求を処理し、ファイルスペースの共有制御をおこなう共有ファイルシステムが重要な役割を果している。共有ファイルシステムにおいては、格納されたデータのconsistencyを保つことが必須の条件であり、処理のatomicity保証の単位としてtransactionの概念を持つに至っている。

トランザクションは、処理のatomicityを保証するためにふたつの主要な制御をもっている。ひとつは、複数依頼者からの処理依頼を論理的には直列に実行することを保証する共有制御であり、いまひとつはシステムの障害に対してファイルが回復可能(recoverable)であることを保証するコミットメント制御である^[1]。

一般にコミットメント制御の概念を持つファイルシステムでは、データ領域の拡張・削除を含む更新処理は、直ちに共有ファイル上には反映されない。つまり、トランザクションがコミットするまでは、当該のトランザクションでのデータ領域の拡張、あるいは削除処理は有効でなくするようなファイル領域管理が要求されるわけである。しかも、領域管理の部分はcritical regionであることが多く、この部分でのオーバヘッドはシステム全体の処理効率を低下させる。

本稿では、Multi-Bit-Mapを用いることにより、極めて小さいオーバヘッドで上記の処理を実現する制御方式^[9]、及び当該方式の実システムへの適用に関する報告をおこなう。

2. トランザクションモデル

本稿で用いるトランザクションの概念について概説する。

システム内には複数のトランザクション($T_1 \dots T_n$)が並行して存在する。トランザクションの処理は、データのREAD/WRITE、LOCK/UNLOCK、あるいはその他の必要な計算から構成されているが、ファイル領域のコミ

ットメント制御を論じる上で、ここではファイル領域に対するALLOCATE操作とDEALLOCATE操作に着目する。各トランザクションの処理は、開始要求(STAT-TRANSACTION)で開始され、ALLOCATE/DEALLOCATE操作の系列によって構成される。

トランザクションの終了は、二相コミットに基づいて実行される。第一の段階としてPRECOMMITが発行され、これに引き続いだ終了要求(COMMIT/ROLLBACK)が発行される。COMMITは、トランザクションの正常な終了を要求し、当該のトランザクションが発行したすべてのALLOCATE/DEALLOCATE操作の結果を有効なものとする。一方、ROLLBACKは、PRECOMMITのfail、もしくはなんらかの障害が発生した場合の処理要求であり、当該のトランザクションを構成する操作系列の結果は、すべて無効となる。また、CRASHをシステムの障害として定義する。CRASHが発生すると、実行中のトランザクションを構成する操作系列のすべてが無効となる。

共有ファイルFは、分割された複数個(m個)の部分(ブロック)の集合から構成され、以下のように表現される。

$$F = \{ b_1, \dots, b_m \}$$

トランザクションでのALLOCATE/DEALLOCATE操作は、すべてこのブロックを単位として実行されるものとする。

3. コミットメント制御の状態遷移による記述

3. 1 定常状態

ある時点において各ブロックは、割当て済(allocated)、または未割当て(free)のいずれかの状態のみをとり得る。これらのブロックの状態の集合が、その時点でのファイルの定常状態であり、ブロックの状態を $s(b_k)$ で表すと、

$$S(F) = \{ s(b_1), \dots, s(b_m) \}$$

として表現することができる。

ファイルの定常状態は、COMMIT/ROLLBACK/CRASHのうち、COMMITの実行によってのみ遷移し、他の処理によっては変化してはならない。この様子を示したのが図-1である。

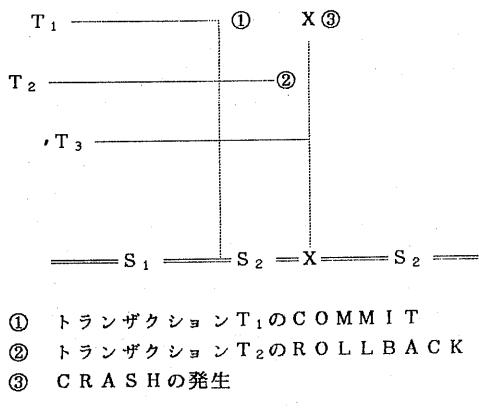


図-1: ファイルの定常状態の遷移

3.2 中間状態

定常状態においては各ファイルブロックの状態は、allocated、または、freeのいずれかのみである。トランザクション T_i でALLOCATE操作の対象となったブロックは、COMMITにより、freeからallocatedへの遷移をatomicに起こす。DEALLOCATE操作の場合は、この逆である。

これをさらに分解して考察する。トランザクション T_i でALLOCATE操作の対象となったブロック b_k の定常状態 $s(b_k)$ は、 T_i が終了するまでは free を保持しなければならない。しかし、同時にシステム内に存在する他のトランザクション T_j にも、 b_k をALLOCATE操作の対象とすることを許すならば、 T_i と T_j の COMMIT で、 b_k が二重に割当てられたことになり、明らかな inconsistency が生じる。つまり、ブロック b_k は、定常状態は free でありながら、システム内のすべてのトランザクションから見ると allocated であり、かつトランザクション T_i に対して allocated であるという中間状態、

言いかえれば割当てられようとしている状態に遷移しなければならない。

同様にトランザクション T_i 中で DEALLOCATE 操作の対象となったブロック b_k は、 T_i に対して free の状態となるが、 T_i の COMMIT 以前に他のトランザクションに b_k への ALLOCATE 操作を許すならば、 T_i の ROLLBACK が不可能になる。従って b_k は、トランザクションからは free でありながら、一方で定常状態は allocated であるという中間状態、すなわち解放されようとしている状態に遷移することを要求される。

定常状態が free で、トランザクション T_i には allocated であるようなブロックの状態を、 T_i に対して intending-to-allocate 状態にあると呼び^[6]、一方定常状態が allocated でかつトランザクション T_i にとって free であるようなブロックの状態を、トランザクション T_i に対して intending-to-free である^[6]とする。ただし、ALLOCATE 操作の対象となり得るブロックは、free であり、かつ intending-to-allocate でないものであり、DEALLOCATE 操作の対象となり得るブロックは、allocated であり、かつ intending-to-free でないものである。

以上から自明なように、ファイル F は、定常状態 $S(F)$ のほかに、システム内の全トランザクションが認識する中間状態 (intending state) $C(F)$ と、トランザクションごとに對応した中間状態 $I_i(F)$ を持つことになる。これらの中間状態に對応するブロックの状態をそれぞれ、 $c(b_k)$ 、 $i_{ii}(b_k)$ とすれば $C(F)$ と $I_i(F)$ は $S(F)$ と同じように以下のように表現することができる。

$$C(F) = \{c(b_1), \dots, c(b_m)\}$$

$$I_i(F) = \{i_{ii}(b_1), \dots, i_{ii}(b_m)\}$$

この中間状態は、ALLOCATE/DEALLOCATE、及び PRECOMMIT の処理によって逐次に遷移する。 $S(F)$ は、トランザクション T_i の COMMIT で、この中間状態に依存して、次の定常状態 $S'(F)$ へ遷移することになる（図-2 参照）。

3.3 状態の Multi-Bit-Map 表現

前節で示したファイルの状態の表現方法について記述する。

すでに述べたように、定常状態 $S(F)$ は、

F を構成するブロック b_k の定常状態の集合であり、また中間状態 $C(F)$ 、及び $I_i(F)$ はやはりブロック b_k の中間状態の集合であって、以下のように表現することができた。

$$S(F) = \{s(b_1), \dots s(b_m)\}$$

$$C(F) = \{c(b_1), \dots c(b_m)\}$$

$$I_i(F) = \{i_i(b_1), \dots i_i(b_m)\}$$

各ブロックの定常状態はfreeであるか、またはallocatedであるから、 $S(F)$ は、共有ファイルを構成するブロックの集合 $\{b_1, b_2 \dots b_m\}$ の各要素を1ビットで表現したビットマップに置きかえることが可能である。この定常状態を表現したビットマップがSAM(Stable Allocation Map)である。

まったく同様に、中間状態も、ブロックの中間状態(intending-to-free, intending-to-allocate)をそれぞれ1ビットで表現したビットマップに置きかえることができる。全トランザクションの認識する中間状態を表現するのがCOM(Common Map)であり、トランザクションごとに対応する中間状態を示すビットマップがTAM(Transaction Allocation Map)である。ある時点でのシステム内のトランザクションの状態は、定常状態を表現するビットマップSAMと、中間状態を表現するCOM、システム中に存在するトランザクションに対応する中間状態を表現する複数のTAMにより一意に表現されることになる。

3.4 状態遷移の考察

トランザクションの状態は上記のように、Multi-Bit-Mapを用いることで表現できることを示した。SAM、COM、TAMはそれぞれ共有ファイルの定常状態、中間状態、トランザクションごとの中間状態を示している。一方、あるブロックに対応するこれら三種類のビットマップのビットの組み合わせは、ある時点でのブロックの遷移状態を示しているものとして捉えることができる。以下では、トランザクション T_i 中の各処理(START-TRANSACTION、ALLOCATE、DEALLOCATE、PRE COMMIT、COMMIT、ROLLBACK)を要因とするブロックの状態の遷移を記述する。

(1) START-TRANSACTION

図-2に示すように、トランザクション T_i の開始時には、中間状態 $I_i(F)$ と定常状態は一致しているものと見ることができ、START-TRANSACTIONでは、 $I_i(F)$ を、 $S(F)$ のcopyとして生成すればよいことがわかる。すなわち、SAMをcopyして T_i に対応するTAMを生成すればよい。

(2) ALLOCATE操作

すでに述べたようにfreeであり、intending-to-allocateでないブロック b_k を選択し、対応する $I_i(f)$ の $i_i(b_k)$ をintending-to-allocateとする。

(3) DEALLOCATE操作

ALLOCATE操作と同様に、allocatedであり、intending-to-freeでないようなブロック b_k を選択し、対応する $I_i(F)$ の $i_i(b_k)$ をintending-to-freeとする。

(4) PRE COMMIT

PRE COMMITをSAM、COM、TAMの三種類のビットマップの、各ブロックに対応するビットごとにに対するビットマップ演算として定義し、表-1に示す。

SAM COM TAM TAM(遷移後)

	SAM	COM	TAM	TAM(遷移後)
①	0	0	0	0
②	0	0	1	0
③	0	1	0	0
④	0	1	1	1
⑤	1	0	0	0
⑥	1	0	1	0
⑦	1	1	0	0
⑧	1	1	1	1

表-1: PRE COMMITによる遷移
(ブロック b_k に対応する)

これら三種類のビットマップのビット組み合せが意味するファイルの状態は以下のようになる。

- ①: b_k は freeである。
- ②: b_k は T_i 開始時には allocated。 T_i 処理中に freeへ遷移した。
- ③: b_k は T_i 開始時には free。現在他のトランザクションに intending-to-allocate。
- ④: b_k は T_i に intending-to-allocate。
- ⑤: b_k は T_i に intending-to-free。
- ⑥: b_k は T_i 開始時には allocated。現在他のトランザクションに intending-to-free。
- ⑦: b_k は T_i 開始時には free。 T_i 処理中に allocated へ遷移した。
- ⑧: b_k は allocated である。

表-1に示された状態の遷移を記述する論理演算は、

$$TAM = COM \text{ and } TAM$$

と表現される。この論理式は、当該のトランザクションに intending-to-allocate であるブロックのみが precommitting-to-allocate の状態に遷移し得ることを示している。

(5) ROLLBACK

同様に三種類のビットマップのビットに対する論理演算を定義する。

SAM COM TAM COM (遷移後)

	SAM	COM	TAM	COM	(遷移後)
①	0	0	0	0	0
②	0	0	1	0	0
③	0	1	0	1	1
④	0	1	1	0	0
⑤	1	0	0	1	1
⑥	1	0	1	0	0
⑦	1	1	0	1	1
⑧	1	1	1	1	1

表-2: ROLLBACKによる遷移
(ブロック b_k に対応する)

- ①: 表-1の①と同じ。
- ②: b_k は、 T_i の開始時には allocated。 T_i の処理中に freeに遷移した。
- ③: b_k は、他のトランザクションに対して intending-to-allocate になった。
- ④: b_k は、 T_i に対して precommitting-to-

-allocate。

- ⑤: b_k は、 T_i に対して precommitting-to-free である。
- ⑥: b_k は、他のトランザクションに対して、 intending-to-free である。
- ⑦: b_k は、 T_i の開始時には free。 T_i の処理中に allocated へ遷移した。
- ⑧: 表-1の⑧と同じ。

表-2から、状態の遷移を記述する論理演算を導くと、

$$\begin{aligned} COM &= (COM \text{ and } SAM) \text{ or} \\ &\quad (TAM \text{ and} \\ &\quad (COM \text{ or } SAM)) \end{aligned}$$

となる。第一項は、 b_k の定常状態が allocated でかつ intending-to-free でないことを示し、第二項は、 b_k が T_i により intending-to-free となっていたことを示している。

(6) COMMIT

PRECOMMIT と同様に三種類のビットマップ上のブロック b_k に対応するビットへの論理演算として COMMIT 処理を記述し、表-3に示す。前述のように、ファイルの定常状態は COMMIT によってのみ遷移するものであるから、遷移の対象となるのは定常状態を示す SAM でなければならぬ。

SAM COM TAM SAM (遷移後)

	SAM	COM	TAM	SAM	(遷移後)
①	0	0	0	0	0
②	0	0	1	0	0
③	0	1	0	0	0
④	0	1	1	1	1
⑤	1	0	0	0	0
⑥	1	0	1	1	1
⑦	1	1	0	1	1
⑧	1	1	1	1	1

表-3: COMMITによる遷移
(ブロック b_k に対応する)

- ①: 表-1の①と同じ。
- ②: b_k は、 T_i の PRECOMMIT 時には allocated。 T_i の COMMIT 前に freeへ遷移

した。

- ③: b_k は、他のトランザクションに対して **intending-to-allocate** になった。
- ④: b_j は、 T_i に対して **precommitting-to-allocate** である。
- ⑤: b_k は、 T_i に対して **precommitting-to-free** である。
- ⑥: b_k は、他のトランザクションに対して、**intending-to-free** である。
- ⑦: b_k は、 T_i の **P R E C O M M I T** 時には **free**。 T_i の **C O M M I T** 前に **allocated** へ遷移した。
- ⑧: 表-1 の⑧と同じ。

表-3 に示された状態の遷移を記述する論理演算は、

$$\begin{aligned} S A M = & (T A M \text{ and } C O M) \text{ or} \\ & (S A M \text{ and } \\ & (C O M \text{ or } T A M)) \end{aligned}$$

式の第一項は、ブロック b_k を、 T_i が **A L L O C A T E** 操作の対象としたことを意味する。第二項は、 T_i が **D E A L L O C A T E** 操作の対象としなかったことをそれぞれ意味している。

以上のように本項では、共有ファイルシステムにおけるトランザクションの状態を、ブロックの定常状態、中間状態、トランザクションごとの中間状態の組み合わせで表現し、それらの状態遷移に着目することで、極めてオーバヘッドの小さなコミットメント制御方式のモデルを提案した。

3.5 处理例

本稿では、分散システムの実現を意識して、二相コミットの概念を含めた処理方式の検討を行ってきた。ここで、該方式のサブセットとして、集中型の共有ファイルシステムで、**A L L O C A T E** 操作のみをサポートした例を図-3 に示し、以下に処理を格段階ごとに概説する。ただし、簡単のために四個のブロックの管理を行うものとする。

(step1) トランザクション T_1 の **S T A R T** - **T R A N S A C T I O N** に伴う $T A M_1$ の生成

(step2) T_1 の **A L L O C A T E** 操作により (1 個のブロックの割り当て要求) **C O M** と $T A M_1$ の対応するビットがセットされる。

(step3) トランザクション T_2 の **S T A R T** - **T R A N S A C T I O N** に伴う $T A M_2$ の生成

(step4) T_2 の **A L L O C A T E** 操作により (2 個のブロックの割り当て要求) **C O M** と $T A M_2$ の対応するビットがセットされる。

(step5) T_2 の **C O M M I T** (表-3 参照)

(step5) の直後に **C R A S H** が発生し、**C O M** と **T A M** の保持する情報が失われた場合には、**S A M** には T_2 がコミットした状態のみが残される。この例は、トランザクションの **atomicity** 保証が効果的に実現されていることを示している。

4. 実システムへの適用

著者らは以下の理念に基づき、ローカルネットワーク上に存在する各種アプリケーションから利用されるネットワーク上の大容量ファイリングシステム…ファイルサーバ…を開発した^[9] (図-4)。

- オフィスに散在する可変長・大容量データの効率的格納、及び敏速なアクセスの実現。
- 共有利用のための基本機能実現。
- 統合環境支援。

領域管理方式の決定にあたっては、データアクセス速度、ファイルスペースの割当・解放処理オーバヘッド、及びファイルスペース利用効率の三点を考慮しなければならない^[11]。その一方、共有ファイルシステムとしての性格上、共有制御、及びコミットメント制御の概念を含んだトランザクション処理が必須の機能となり、これらの両制御をいかに効率よく実現するかの考察が必要となった。

4.1 ファイルサーバのファイル構造

ファイル構造の詳細について本稿では触れない。大雑把な構造として、システム依存のシステムデータ領域と、ユーザに利用されるユーザデータ領域とから構成され、両者がリンクされた形をとっている。

ただし、注意しておかなければならないことは、本システムがデータベース同様、トランザクションの機能を持つものの、性質は多少異なって

いる点である。通常のデータベースが定型で、比較的小さな単位のデータを扱うのに対し、ファイルサーバは、本来不定長で、かつ大規模なサイズのデータを取りあつかえることを主眼として設計されたシステムである。このために、本システムの基本的な領域管理機構として、可変長のファイル領域の処理を可能とするメカニズムが要求された。

可変長データの効率的格納と高速なアクセスを実現するため、著者らは以下に示す二点の考査のもとに、Buddy algorithm^[2, 3]に基づくファイル領域管理方式…Buddy方式を採用した。

■ 高速なデータアクセス実現のためには可変長で、かつ連續的なファイルスペース割当てを可能としなければならない。Buddy algorithmは、この要求を満足する領域割当て方式を提供する。

■ 一般的に Buddy algorithmは、処理速度に優越し利用効率においては若干劣るとされる。しかし、基数をフィボナッチ数列にとる Fibonacci-Buddy を用いたシミュレーションによれば、全体としてのフラグメンテーションは最悪でも 30% を越えず^[8]、実用上充分な利用効率を得られる事が実証された。

4. 2 コミットメント制御方式

コミットメント制御の基本的な考え方たは次のように要約することができる。

データの更新要求を直ちに実際のファイルに反映させるのではなく、一時的に別のあき領域に書き込んでおき、トランザクション処理の終了とともに実際の更新をおこなう^[4] もので、この考え方たを実現する方法としては、shadow方式と log 方式がある。

本システムで採用したのが、shadow方式である。データは、current と shadow の二つの versionを持ち、更新処理は current version にのみ反映させておき、トランザクションのコミットとともに、shadow versionを破棄することで、容易にコミットメント制御を実現することができる。

しかし、この方式は、Buddy方式に基づく動的な基本的な領域管理方式と組み合せた場合には、処理時間の点でオーバヘッドを生じた。Buddy方式は、データのアクセス速度、ファイル領域の利用効率という点で満足できる方式である。しかし、shadow方式を実現するためには、更新処理時に

current version を新たに割当てなければならず、トランザクションコミット時には shadow version を解放しなければならない。動的な領域管理を実現するために Buddy 方式では、ブロックの割当て・解放にともなってブロックを分割、あるいは統合しなければならず、これらの処理は二次記憶へのアクセスの頻度を高め、処理速度を低下させるという欠点を招いた。

4. 3 Multi-Bit-Map 方式との結合

Buddy 方式に基づく動的な領域管理方式のもう一つでは、ブロックのサイズと個数は常に動的である。このために、このままでは Multi-Bit-Map によるコミットメント制御をそのまま適用することはできない。ファイルサーバシステムの特性として、どのようなサイズのブロックがそれぞれ幾つ必要であるかを予め厳密に定めておくことができない。また、強いてそのようなことをおこなえば、大容量で可変長のデータを扱うという設計目標に反することになる。

このような問題を解決し、かつ動的な領域の割当て・解放にともなうオーバヘッドを軽減するために、Pre-allocate 方式を導入する。これは、処理要求頻度の高い特定サイズの領域を予め固定的に割り当てる手法である^[5]。本システムでは、システム依存の領域をこの Pre-allocate 方式の処理対象領域とし、Pre-allocate された当該ブロックを、本稿で述べた Multi-Bit-Map によってコミットメント制御の対象とした。

システム依存領域を対象としたのは、この領域のサイズが固定であり、かつ最も処理の要求頻度が高かったこと。また、Buddy 方式では、ブロックのサイズが小さくなるほど、割当て・解放にともなうオーバヘッドが増すという結果が得られていたことによる。

本ファイルサーバシステムには、本稿で述べた制御のサブセットを適用したのみである。しかし、本方式を適用しなかった場合に比較すると、処理効率の著しい向上が見られ、Multi-Bit-Map 表現に基づくコミットメント制御方式が極めて有効なものであることを実証した。

5. あとがき

本稿では、トランザクション状態を Multi-Bit-Map を用いて表現し、そのコミットメント制御を状態遷移を表す論理演算としてモデル化することで、オーバヘッドの少ない効率的な制御方式が実現可能であることを示した。また、実シス

テムにそのサブセットをインプリメントしたのみでも顕著な効果が期待出来ることをあわせて示した。

著者らは現在のファイルサーバシステムをマルチクライエント・マルチトランザクション処理をサポートする分散共有ファイルシステムに拡張して、Multi-Bit-Map表現によるコミットメント制御をより有効に機能させることで、負荷及び機能分散による一層の効率向上を計画している。

謝辞: 最後に、本研究をまとめるにあたり、御指導頂いた熊白部長、疋田課長ならびに関係者各位に深謝致します。

6. 参考文献

- [1] Svabodoba. File Servers for Network-Based Distributed Systems. Comp. Survey. Vol. 16. No. 4. 1984
- [2] Peterson. Buddy Systems. CACM Vol. 20. No. 6. Jun. 1977
- [3] Shen. A Weighted Buddy Method for Dynamic Storage Allocation. CACM. Vol. 17. No. 1. 9. 1974
- [4] Brown. The Alpine File System. ACM TOCS. Vol. 3. No. 4. Nov. 1985
- [5] Morgolin. Analysis of free-storage algorithm. IBM system journal. Vol 10. No4. 1971
- [6] Michell. A Comparison of Two Network-Based File Servers. CACM. Vol. 25. No. 4. Apr. 1982
- [7] Lampson. Distributed Systems: Architecture and Implementation: An Advanced Course. Springer-Verlag , 1983
- [8] 水町他、大量データの格納に関するBuddy法の評価、第29回情報処理学会全国大会
- [9] 吉田他、オフィス環境におけるファイルサーバシステムの実際、マルチメディア通信と分散処理研究会（昭和61年2月）
- [10] 吉田他、ファイルサーバシステムの開発
 - (1) 構想と構成、第32回情報処理学会全国大会発表予定
 - (2) コミットメント制御方式、第32回情報処理学会全国大会発表予定
 - (3) 共有制御方式、第32回情報処理学会全国大会発表予定
- [11] 横山他、ファイルサーバシステムの開発
 - (2) コミットメント制御方式、第32回情報処理学会全国大会発表予定
- [12] 小寺他、ファイルサーバシステムの開発
 - (3) 共有制御方式、第32回情報処理学会全国大会発表予定
- [13] 吉田他、ファイルサーバシステムの開発

(4) 評価と展望、第32回情報処理学会全国大会発表予定

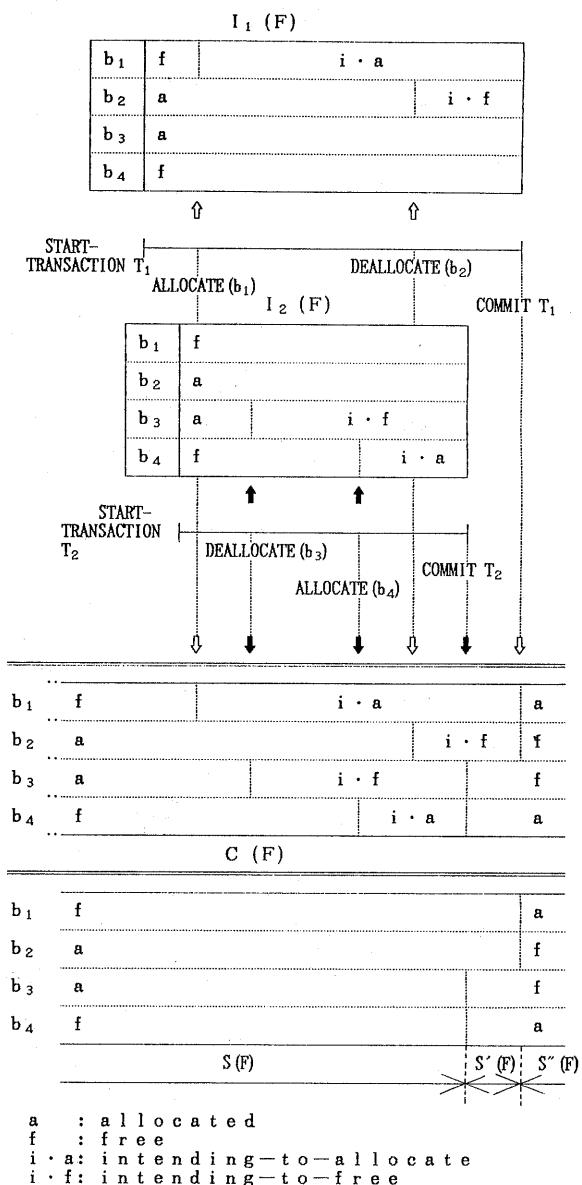


図-2: 定常状態と中間状態

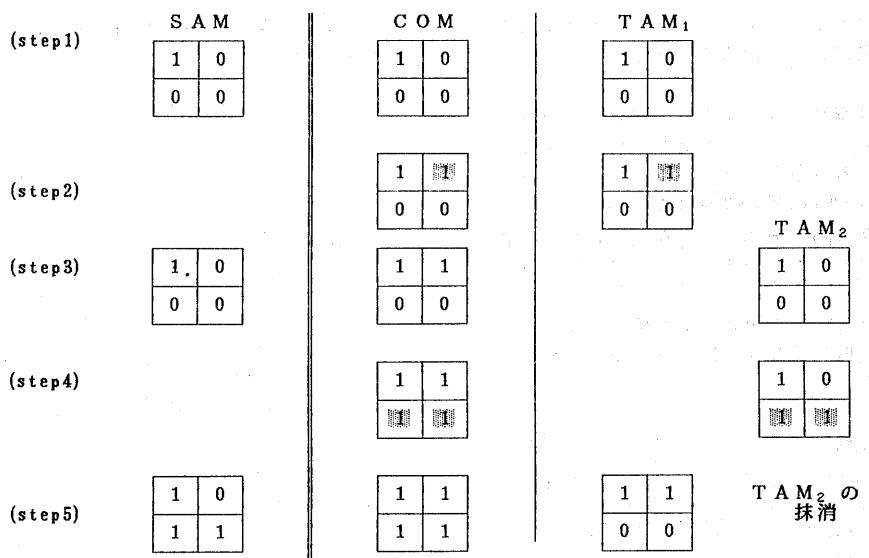


図-3: Multi-Bit-Mapの適用例

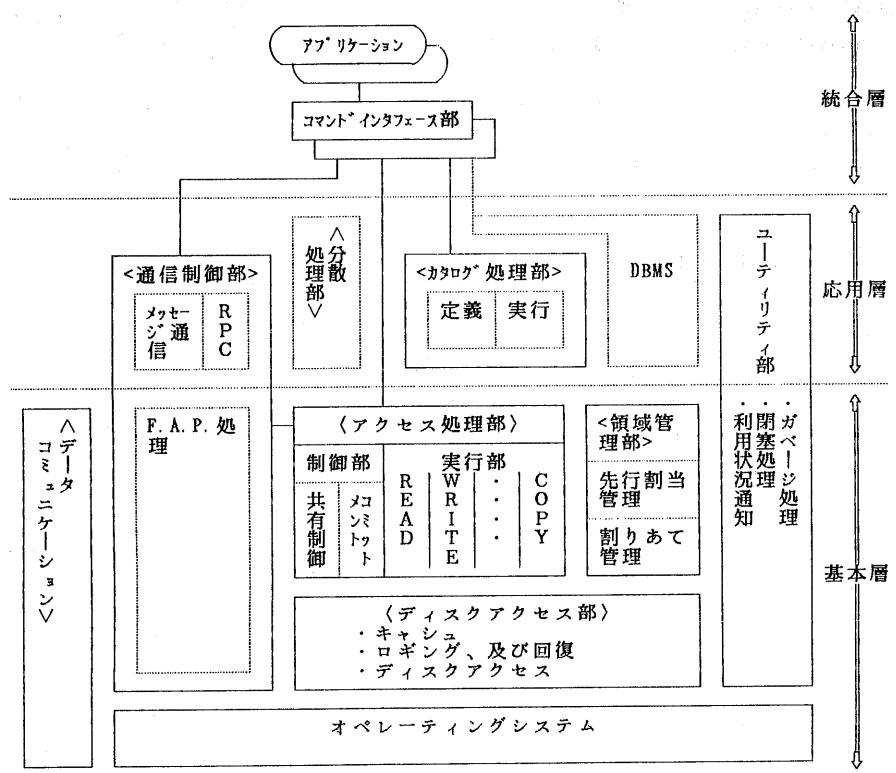


図-4: ファイルサーバシステムの構成