

パス情報を用いた分岐フィルタ機構

三輪 忍^{†1} 福山 智久^{†1} 嶋田 創^{†1}
 五島 正裕^{†2} 中島 康彦^{†3}
 森 眞一郎^{†4} 富田 眞治^{†1}

PHT (Pattern History Table) における破壊的競合を抑制する方法にフィルタ機構がある。フィルタ機構では、強偏向の分岐命令は PHT を使用しないようにすることで、PHT の予測ミス率を低下させる。一方、パス情報が予測の手がかりになることが最近になって分かってきた。そこで本稿では、フィルタ機構においてパス情報を利用する手法を提案する。強偏向のパスは PHT を使用しないようにすることで、予測ミス率の低下を狙う。本手法を Global Perceptron Predictor に適用した場合、平均 0.14% ミス率が低下した。特に、go においては 0.7% のミス率低下が見られた。また、本手法を Path Based Predictor, Path Trace Predictor に適用した場合でも、go において 0.6~0.7% のミス率低下が見られた。

Branch Filtering Mechanism with Path Trace

SHINOBU MIWA,^{†1} TOMOHISA FUKUYAMA,^{†1} HAJIME SHIMADA,^{†1}
 MASAHIRO GOSHIMA,^{†2} YASUHIKO NAKASHIMA,^{†3}
 SHIN-ICHIRO MORI^{†4} and SHINJI TOMITA^{†1}

Branch filter mechanism is a method which reduces destructive aliasing on PHT (Pattern History Table). This improves the misprediction rate not to use PHT for the branches with strong tendencies. Otherwise, it proves recently that path traces are hint for branch predictions. So, we propose branch filter mechanism with path traces. It is supposed that this mechanism improves the misprediction rate not to use PHT for the path trace with strong tendencies. When this mechanism is implemented on Global Perceptron Predictor, the average misprediction rate is reduced by 0.14%. Especially, the misprediction rate of go is reduced by 0.7%. And, when proposal mechanism is implemented on Path Based Predictor, on Piecewise Linear Predictor, and on Path Trace Predictor, the misprediction rate of go is reduced by 0.6~0.7%.

1. はじめに

近年では、マイクロプロセッサの高クロック化にともない、パイプラインは深化傾向にある⁹⁾。その一方、パイプラインの深化は、分岐予測ミス・ペナルティの増大をもたらす。分岐予測ミス時のペナルティは、命令パイプラインの命令フェッチ・ステージから実行ステージまでのサイクル数で与えられる。そのため、分岐予測のヒット率の改善は重要な課題となっている。

これまでに数多くの分岐予測器が提案されてきたが、その大半は飽和型カウンタを用いた方式であった。通常、2 bit (以下 b とする) のカウンタをエントリとする、PHT (Pattern History Table) と呼ばれるテーブルが用いられる。最も単純な方式では、PHT のインデクスに、分岐命令のアドレスの下位の一部を用いる。

最も代表的な g-share 分岐予測器⁶⁾ では、PHT のエントリを指し示すインデクスの一部にグローバル分岐履歴 (global branch history) を加えることで、ヒット率の向上を狙っている。

しかし、インデクスの一部にグローバル分岐履歴を用いる方式では、同一の分岐に対しても、出現するグローバル分岐履歴のパターンの数だけエントリを更新することになる。その結果、競合がなければ予測ヒットするが実際にはミスする競合、すなわち、破壊的競合 (destructive aliasing)¹⁾ の発生確率が上昇してし

^{†1} 京都大学
Kyoto University

^{†2} 東京大学
The University of Tokyo

^{†3} 奈良先端科学技術大学院大学
Nara Institute of Science and Technology

^{†4} 福井大学
Fukui University

まう。

破壊的競合による予測精度の低下を防ぐ方法に、フィルタ機構²⁾がある。フィルタ機構では、Taken, Untaken のどちらかに強く偏向している分岐命令を予測器による予測の対象から外すことで、予測ヒット率を向上させている。

パーセプトロンを用いた分岐予測器

予測ヒット率を向上させるには、一般に、グローバル分岐履歴は長い方がよい。ところが、g-share では、グローバル分岐履歴長の指数に比例するメモリ量が必要であった。分岐予測器に割けるメモリ量は数 KByte (以下 KB とする) からせいぜい数百 KB 程度で、その範囲内では十数個分の履歴しか扱えない。

Jiménez らはそれに対して、パーセプトロン⁸⁾を用いた分岐予測器を提案している³⁾。パーセプトロンを用いた分岐予測器では、必要なメモリ量は、グローバル分岐履歴長に比例する。結果、同メモリ量で比較的長い履歴を用いることができ、既存の方式よりも高い予測ヒット率を示している。

ただし、パーセプトロンを用いた分岐予測器は多くの計算量を必要とする。予測に際しては、整数の加減算が、履歴長に比例した回数行われる。そのため、履歴長は、フェッチしてから実行するまでのパイプライン・ステージ段数に支配される。

そこで、予測処理をパイプライン化する方法⁴⁾が提案された。パイプライン化された分岐予測器では、分岐命令がフェッチされるたびに、そのときの分岐命令のアドレスによって重みを求め、それを累積する。予測する命令がフェッチされると、累積値を使って予測する。

パス情報と分岐予測

予測処理のパイプライン化は大きなパラダイムシフトとなった。それまでは、予測の手がかりとなる情報といえば (ローカル/グローバル) 履歴と予測する分岐命令のアドレスであった。それがパイプライン化によって、分岐命令のアドレスの履歴、すなわち、パス情報も強力な手がかりとなることが分かってきた。

現在は、パス情報を利用することで予測ヒット率を向上させた分岐予測器が、数多く提案されている^{5),10)}。

本稿では、フィルタ機構においてパス情報を利用する方法を提案する。上述のように、フィルタ機構では、強偏向の分岐命令は予測器を使用しないようにすることで、予測ヒット率を向上させる。それと同様、強偏向のパスは予測器を使用しないようにすれば、より高い予測ヒット率を実現できるだろう。




図 1 Filter 機構

Fig. 1 Branch filter mechanism.

以下まず次章では、フィルタ機構、および、パス情報を利用した分岐予測器について詳しく述べる。続く 3 章では、予備評価として強偏向のパスがプログラム中にどの程度存在するかを示し、それらをフィルタリングする機構を提案する。評価は 4 章で行う。

2. 関連研究

本章では、破壊的競合を緩和する方法としてよく知られた、フィルタ機構についてまず述べる。次いで、近年主流になりつつある、パス情報を利用する分岐予測器について述べる。

2.1 フィルタ機構²⁾

フィルタ機構は、予測器を使用する対象から強偏向の分岐命令を外すことで、予測ヒット率を向上させる方法である。プログラム中、always Taken, always Untaken の分岐命令は全分岐命令の約 50% を占めていることが知られている²⁾。このような分岐命令は予測器を使用しないようにすれば、PHT における破壊的競合を減らせる。

フィルタ機構の構成を図 1 に示す。図では、予測器には、後述する GPP (Global Perceptron Predictor) を用いている。

フィルタ機構は、BTB (Branch Target Buffer) の各エントリに 2 つのフィールドを追加することで実現される。1 つは確信度カウンタ (図 1 中では confidence counter) と呼ばれる 2~3b の飽和型カウンタで、これにより分岐結果の偏りを検出する。その初期値は 0 とする。もう 1 つはバイアス・ビット (bias bit) と呼ばれる 1b のフィールドで、これは偏向している方向を (Taken を 1, Untaken を -1 で) 表す。

フェッチした分岐命令が BTB にヒットしたとき、フィルタ機構を用いた予測は、次のようにして行う。まず、ヒットしたエントリの確信度カウンタを参照する。結果、確信度カウンタが：

全ビット 1 だった場合 バイアス・ビットの値を予測結果とする。分岐予測器は使用しない。

それ以外の場合 分岐予測器（図では GPP）を使用し、その結果を予測結果とする。

なお、BTB にミスしたときは、分岐予測器を使用せずに Untaken を返す⁷⁾。

フィルタ機構の更新は以下のようにして行う：

- ヒットしたエントリのバイアス・ビットと分岐結果が一致した場合、確信度カウンタをインクリメントする。
- 一致しなかった場合、バイアス・ビットを反転し、確信度カウンタを 0 にする。

なお、分岐予測器の更新はそれを使用したときのみ行う。

たとえば、3b の確信度カウンタを持つフィルタ機構で、always Taken の命令を予測するとして。この命令が最初にフェッチされたとき、カウンタは 0 であるため、予測器が使用される。そして、バイアス・ビットに 1 がセットされ、カウンタは 1 になる。2 回目も、カウンタはまだ最大値になっていないため、予測器が使用されカウンタが 1 増える。そして、8 回目になると、カウンタは最大値になっているため、バイアス・ビットが使用される。以降、この命令の予測には、すべてバイアス・ビットが使用されることとなる。

このようにして、フィルタ機構は、強偏向の分岐命令が予測器を使用するのを防ぐ。

2.2 パス情報を利用する分岐予測器

冒頭で述べたように、近年では、パス情報を利用した分岐予測器の研究が盛んになっている。本節では、そうした予測器である、PBP (Path-Based Predictor)、および、PTBP (Path Trace Branch Predictor) について述べる。

これらの予測器は、GPP (Global Perceptron Predictor) をベースに発展してきた。そこで、まずは GPP について述べることにしよう。GPP 自体は、パス情報を利用していない点に注意されたい。

2.2.1 GPP (Global Perceptron Predictor)³⁾

図 2 に、GPP の構成を示す。予測においてはパーセプトロンが中心的な役割を果たす。パーセプトロンにグローバル分岐履歴を入力して分岐予測を行う。なお、入力として、グローバル分岐履歴だけでなくローカル分

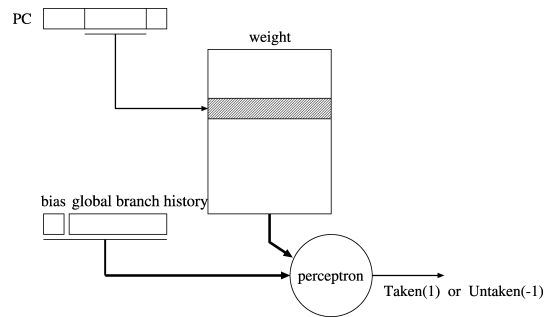


図 2 GPP (Global Perceptron Predictor)

Fig. 2 GPP (Global Perceptron Predictor).

岐履歴も用いた、Global/Local Perceptron Predictor も提案されている。

重みセット (weight set) は複数用いる。それらは、PC をハッシングしたものをインデクスとするテーブルに格納されている。予測に際しては、分岐命令のアドレスを用いてテーブルにアクセスする。ただし、g-share などとは異なり、インデクスの生成にはグローバル分岐履歴を用いない。分岐命令に対して 1 つの重みセットが選ばれることになる。この重みセットをパーセプトロンの重みとし、グローバル分岐履歴を入力として、予測を行うのである。

入 力

入力は $1(\text{Taken})/-1(\text{Untaken})$ で与えられる。

重 み

8 ビット符号付き整数型で表される。入力も $1/-1$ であるために、積和の計算が加減算に帰着できる。

出力と予測

積和が 0 以上のとき $1(\text{Taken})$ 、そうでなければ $-1(\text{Untaken})$ を出力する。

上述のように、パーセプトロンの入力の長さは履歴長 によって与えられる。そして、その分の加減算が、予測に際して行われる。したがって、履歴が長いと、予測結果が実行ステージに間に合わなくなってしまう。

そこで、予測処理をパイプライン化した PBP が提案された。それでは、次は PBP について述べることにしよう。

2.2.2 PBP (Path-Based Predictor)⁴⁾

前項で述べたように、GPP のボトルネックは、履歴長分の整数の加減算であった。そこで、予測処理をパイプライン化し、1 ステージに行うのは加減算 1 回とすることで、長い履歴を用いた予測を可能にする。

図 3 に PBP の構成を示す。PBP は、GPP のテー

正確にはバイアスも含め (履歴長 + 1)。

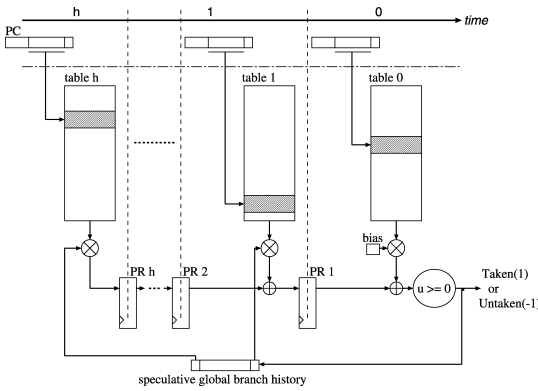


図 3 PBP (Path Based Predictor)
Fig. 3 PBP (Path Based Predictor).

ブルを履歴方向に分割した構成となっている。すなわち、PBP のテーブルのエントリは、重みセットではなく重みである。各テーブルを履歴順にテーブル $0, 1, \dots, h$ とする。テーブル間には、パイプライン・レジスタ $PR_i (i = 1, \dots, h)$ が設けられている。

予測は投機的に行う。たとえば、履歴長が h の場合、ある分岐命令がフェッチされると、その h 個先の分岐命令の予測を開始する。したがって、ある分岐命令がフェッチされた時点では、パイプライン・レジスタによって区切られた h 個の区間において、その分岐命令から h 個先の分岐命令までの予測が行われている。

分岐命令がフェッチされると、PC をハッシングしたものをインデクスとして、以下の処理を行う：

- バイアス⁸⁾を読み出す。それを PR_1 の累積値に加え、予測結果とする。
- テーブル i の重みを読み出す。それと PR_{i+1} の累積値とを加算、または、減算し、結果を PR_i に格納する。加算するか減算するかは、そのときの予測結果によって決定する。

このように、PBP では、履歴長によらず、 PR_1 の値とバイアスとの加算 1 回で予測が行える。

また、この方法の重要な点はパス情報、すなわち、分岐命令のアドレスの履歴が利用されている点である。図に示すように、時刻 0 の分岐命令の予測に使用されるのは、そのときの PC だけではない。その命令の積和を求める過程で、時刻 $1 \sim h$ の PC も使用される。

性能

同メモリ量 (8 KB) の Global /Local Perceptron

Predictor に比べ、SPEC CINT 2000 ベンチマークにおいて予測ヒット率が平均 0.4% 向上するという結果が出ている。

このように、パイプライン化されたにも関わらず、PBP の予測ヒット率は向上する。このことは、パス情報が有効な役割を果たしたといえよう。

2.2.3 PTBP (Path Trace Branch Predictor)¹⁰⁾

最後に、パス情報をより効果的に利用した、PTBP について述べる。

前項で述べた PBP では、アドレスを独立したものとして扱っていた。個々のアドレスは、それぞれ、異なるテーブルのインデクシングに利用される。そして独立に求めた重みを加算し、パス情報を 1 つの値へとマッピングする。

それに対し、PTBP は、アドレス間の関連性をより直接的に利用する。具体的には、単一アドレスでテーブルをインデクシングするのではなく、複数アドレスの排他的論理和によってインデクシングする。

アドレス間の関連性はなるべく多く利用した方がよい。そこで、以下で詳しく述べるように、PTBP では予測の開始を遅らせている。

図 4 に PTBP の構成を示す。PTBP は、PBP を時間方向に M 等分し、分割したパイプラインを空間方向に並列に並べた構造をしている。ただし、単に並列に並べたものとは、以下のようにインデクシング方法が異なる：

テーブル h/M まで ($1 \sim h/M$) PBP と同じく、そのときの PC をハッシングしたものをインデクスとする。

テーブル h/M 以降 ($h/M + 1 \sim h$) そのときの PC からその履歴の PC までの排他的論理和をハッシングしたものをインデクスとする。ただし、排他的論理和は、20b のローテーション・シフトを繰り返しながら計算する。これは、パス情報に同一 PC が含まれるとき、その排他的論理和が 0 となるのを防ぐためである。簡単のため、排他的論理和をとる PC は h/M 個おきとする。

たとえば、テーブル h のインデクシングには、そのときの PC、 h/M 個前の PC、 $2h/M$ 個前の PC、 \dots 、 h 個前の PC が利用される。このように、PTBP は、アドレス間の関連性を利用する。

性能

後述するように、同メモリ量 (128 KB) の PBP に比べて、SPEC CINT 95 ベンチマークにおいて予測

予測時にはまだ分岐結果が確定していないため、分岐結果ではなく予測結果を用いる。予測結果と分岐結果が異なった場合、当然リカバリが行われるが、その処理は本稿では述べない。

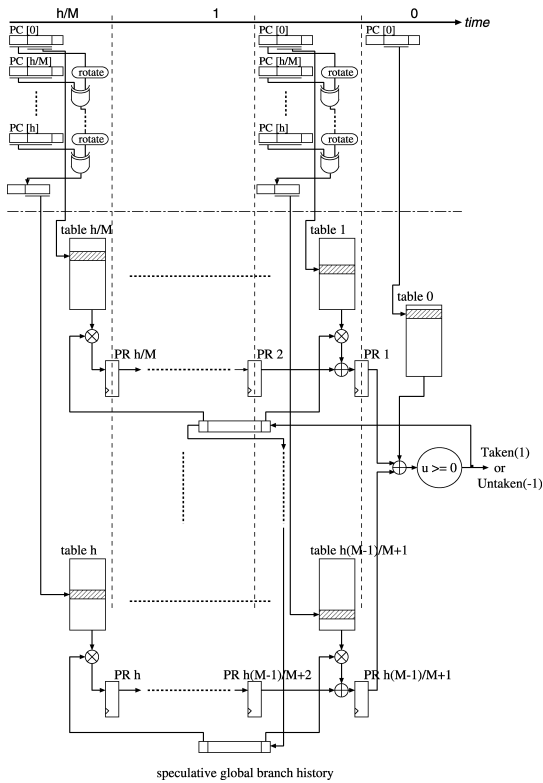


図 4 PTBP (Path Trace Branch Predictor)
Fig. 4 PTBP (Path Trace Branch Predictor).

ヒット率が平均 0.63% 向上するという結果が出ている。

このように、予測ヒット率を改善するうえでパス情報は効果的である。

3. パス情報を用いた分岐フィルタ機構

2.1 節で述べたように、フィルタ機構は、強偏向の分岐命令が予測器を使用するのを防ぐことで、予測ヒット率を向上させる手法であった。一方、2.2.2, 2.2.3 項で述べたように、パス情報が予測精度向上のための強力な手がかりとなることが最近になって分かってきた。

そこで、本稿では、フィルタ機構においてパス情報を利用する手法を提案する。ある分岐命令をある順序で通過した場合、その終端の分岐命令が always Taken, always Untaken になることがある。そうした、いわば、強偏向のパスが予測器を使用するのを防げば、破壊的競合が減り、予測ヒット率は向上するだろう。

以下まず次節で、予備評価として SPEC CINT 95 の 8 本のベンチマークにおいて、強偏向のパスがどの程度存在するかを示す。そして、それらをフィルタリングする機構を 3.2 節で提案する。




図 5 各ベンチマークにおける強偏向のパスの出現率
Fig. 5 Rate of the paths which is always taken or which is always untaken.

3.1 予備評価

前述のように、プログラム中の分岐命令の約半分は強偏向の分岐命令である。すなわち、always Taken, または、always Untaken な分岐命令が半分を占める。そのため、フィルタ機構は高い効果を発揮する。

これと同様のことが、パスについてもいえる。パスの多くが強偏向であれば、パス情報を利用したフィルタリングは、高い効果が期待できる。

SPEC CINT 95 における強偏向のパスの割合を図 5 に示す。グラフの横軸は分岐命令のアドレスの履歴数、すなわち、パス長を、縦軸は強偏向のパスの割合を表す。ここで、強偏向のパスの割合とは、always Taken, または、always Untaken なパスの出現回数を、全パスの出現回数で割ったものである。なお、図は BTB 512set, 4way 時の結果で、BTB にミスするパスは分子/分母ともに含めていない。測定には、SimpleScalar ツールセット (ver. 3.0) の sim-bpred シミュレータを用いた。

グラフより、パス長 1, すなわち、always Taken な分岐命令の割合は、最も少ない go で 1.6%, 最も多い jpeg で 31.7% である。どのベンチマークにおいても、パス長が長くなるほど、強偏向なパスの割合は増加する。パス長が 32 のとき、強偏向なパスの割合は、最も少ない m88 ksim で 50.6%, 最も多い gcc で 77.8% になる。

また、グラフから分かるように、go を除き、強偏向なパスの割合はパス長に対して対数的に増加する。そして、パス長 4~16 程度でほぼ上限 (4~7 割) に達する。いい換えると、パス長が 4~16 あれば、4~7 割のパスはフィルタリングできる。

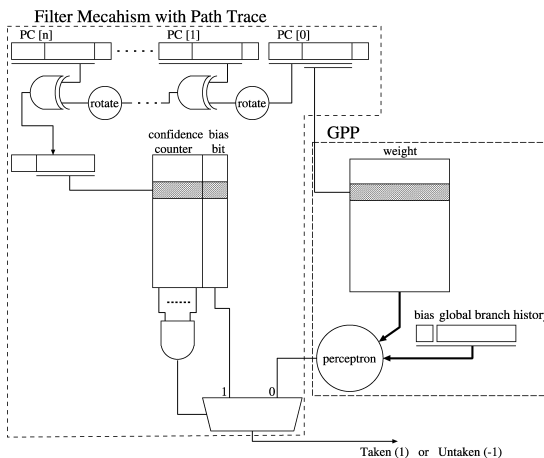


図 6 パス情報を用いたフィルタ機構
Fig. 6 Filtering mechanism with path trace.

3.2 パス情報を用いたフィルタ機構

前節で、強偏向なパスはかなりの割合で存在することが分かった。そこで本節では、そのようなパスをフィルタリングする機構を提案する。

パス情報を用いたフィルタ機構の構成を図 6 に示す。パス情報を用いたフィルタ機構は、通常フィルタ機構（図 1）と同様、確信度カウンタとバイアス・ビットをエントリとするテーブルによって構成する。ただし、通常のフィルタ機構とは以下の 2 点が異なる：

- (1) 分岐命令のアドレスではなく、アドレスの履歴によってインデクシングする。アドレスの履歴は、パス長 (n) 分のアドレスの排他的論理和によって表現する。PTBP と同様の理由により、20b のローテーション・シフトを繰り返しながら排他的論理和を計算する。一方、PTBP とは異なり、排他的論理和は n 個分すべてのアドレスのそれとする。
- (2) タグは存在しない。すなわち、エントリには必ずヒットする。

ヒットした後の動作は、通常フィルタ機構と同様とする。すなわち、ヒットしたエントリの確信度カウンタを参照し：

全ビット 1 だった場合 バイアス・ビットの値を予測結果とする。分岐予測器は使用しない。

それ以外の場合 分岐予測器を使用し、その結果を予測結果とする。

また、更新も通常のフィルタ機構と同様とする。すなわち：

- バイアス・ビットと分岐結果が一致した場合、確信度カウンタをインクリメントする。

- 一致しなかった場合、バイアス・ビットを反転し、確信度カウンタを 0 にする。

たとえば、パス長 4、3b カウンタのパス情報を用いたフィルタ機構で、always Taken な $A_3 \rightarrow A_2 \rightarrow A_1 \rightarrow A_0$ (A_i ($i = 0, \dots, 3$) はアドレス) というパスをフィルタリングするとしよう。 A_0 がフェッチされたとき、まずは、過去 4 つ分のアドレスの排他的論理和 ($A_3 \oplus A_2 \oplus A_1 \oplus A_0$) を求める。そして、それをハッシングしたものをインデクスとしてテーブルを参照する。最初は確信度カウンタが 0 なので、予測器を使用することになる。そして、バイアス・ビットに 1 をセットしてカウンタをインクリメントする。次にこのパスが現れたときも同様に、排他的論理和によってカウンタを参照する。やはり、カウンタは最大値に達していないため、2 回目も予測器を使用し、カウンタをインクリメントする。やがて、このパスが 8 回目に現れると、カウンタは最大値に達しているため、今度はバイアス・ビットにより予測する。以降、このパスが現れても、予測器は使用されなくなる。

このように、提案手法は、強偏向のパスをフィルタリングする。

4. 評価

提案手法を SimpleScalar ツールセット (ver. 3.0) の sim-bpred シミュレータに対して実装し、評価を行った。以下ではその結果を述べる。

4.1 評価環境

以下の 9 通りのモデルを実装し、予測ヒット率を測定した：

- (1) パス情報を利用しない予測器の代表例として GPP。また、パス情報を利用した予測器の代表例として PBP, PTBP の 2 モデル (wo F)。(これら 3 つのモデルの予測ヒット率は、2.2 節で述べたように、 $GPP < PBP < PTBP$ の関係にある。なお、PTBP のパイプラインは 4 本とする)。
- (2) (1) のフィルタ機構付き (w F)。
- (3) (1) のパス情報を利用したフィルタ機構付き (w PTF)。

表 1 に、測定に使用した、各メモリ量 (Hardware Budget) の範囲内で最適化された履歴長とテーブル・サイズを示す。なお、学習の閾値^{3) - 5)} は、履歴長を h として、全モデル $2.1 * (h + 1)$ とした。

測定には、表 2 に示す SPEC CINT95 の 8 本のプログラムを使用した。

BTB は 512set, 4way とした。また、BTB にミス

表 1 最適化された履歴長とテーブル・サイズ
Table 1 Tuned history length and table size for each predictor.

Hardware Budget	wo Filter		w Filter (4K ent.)		w PTBF (4K ent.)		w PTBF (2K ent.)		w PTBF (1K ent.)	
	History	Size	History	Size	History	Size	History	Size	History	Size
4 KB	28	128	16	128	16	128	24	128	28	128
8 KB	28	256	24	256	24	256	28	256	28	256
16 KB	28	512	28	512	28	512	28	512	28	512
32 KB	28	1024	28	1024	28	1024	28	1024	28	1024
64 KB	60	1024	60	1024	60	1024	60	1024	60	1024
128 KB	60	2048	60	2048	60	2048	60	2048	60	2048

表 2 SPEC CINT95 ベンチマーク・プログラム
Table 2 SPEC CINT 95 benchmark programs.

プログラム	入力セット
129.compress95	10000 q 2131
126.gcc	amptjp.i
099.go	9 9
132.jpeg	vigo.ppm
134.perl	primes.in
147.vortex	persons 250
130.li	train.lsp
124.m88ksim	ctl.raw

したときは予測器を使用せず、Untaken を返すようにした⁷⁾。

フィルタ機構、および、パス情報を用いたフィルタ機構の確信度カウンタは、それぞれ、3b とした。

4.2 結 果

パス長に対する性能

図 7 に、パス情報を用いたフィルタ機構のパス長を 4, 8, 16 と変化させたときの、8 本のベンチマークの平均予測ミス率を示す。横軸はメモリ量、縦軸は平均予測ミス率を表す。フィルタ付きのモデルのメモリ量には、フィルタ自体のそれも含まれている点に注意されたい。フィルタは 4K エントリとし、分岐予測器には GPP を使用された。

グラフより、メモリ量 8~32KB の範囲ではパス長 4 のモデルが最も性能が良い。特に 8KB 構成時には、通常の GPP の平均予測ミス率が 4.67% だったのに対し、パス情報を用いたフィルタ機構付き GPP では 4.53% と 0.14% 改善された。

パス長を長くすると逆に性能が悪化するの、インデクシングに用いるパス情報が、以下のように情報圧縮されているためと考えられる：

普通、フィルタ機構は BTB を拡張して実装するため、そのエントリ数は BTB に等しくなる。しかし、BTB とは独立な機構であるパス情報を用いたフィルタ機構と同一エントリのもとで比較するため、本研究ではフィルタ機構も独立に実装した。なお、本来は BTB を拡張して実装されるものであるから、独立に実装したとはいえ、次節の結果ではタグの容量は考慮していない。




図 7 パス長に対する予測ミス率
Fig. 7 Misprediction rate for the length of the path.




図 8 パス情報を用いたフィルタ機構の容量に対する予測ミス率
Fig. 8 Misprediction rate for the size of filter mechanism with path trace.

- (1) パス長分のアドレスを連結するのではなく、排他的論理和をとっている。
- (2) 排他的論理和は 20b のローテーション・シフトを繰り返しながら計算するが、実際にインデクシングに利用するのは、そのうちの数ビット (4K エントリのテーブルでは 12b) である。

また、128KB 構成時では、フィルタなしのモデルが最も性能が良い。これは、メモリ量が多くなると競合自体が減り、フィルタによる予測ミスの影響が相対的に大きくなるためである。

容量に対する性能

図 8 に、バス情報を用いたフィルタ機構のテーブルのエントリ数を 1K, 2K, 4K と変化させたときの、8 本のベンチマークの平均予測ミス率を示す。グラフの見方は図 7 と同様である。バス長は 4 とし、分岐予測器には GPP を使用した。

グラフより、4K エントリのバス情報を用いたフィルタ機構付き GPP が最も性能が良い。「バス長に対する性能」の項でも述べたように、8KB 構成時には、通常の GPP に比べ 0.14%改善される。

バス情報の有無による比較

9 個のモデルの平均予測ミス率を図 9 に示す。グラフの見方は図 7, 8 と同様である。バス長は 4 とし、フィルタ、バス情報を用いたフィルタともにエントリ数は 4K とした。

グラフから分かるように、どの分岐予測器においてもフィルタ機構付きよりバス情報を用いたフィルタ機構付きの方が性能が良い。特に、4KB 構成時には、フィルタ機構付き GPP の予測ミス率が 5.28%だったのに対し、バス情報を用いたフィルタ機構付き GPP

は 5.09%と 0.19%改善された。

図 10 に、8KB 構成時における、ベンチマークごとの予測ヒット率の内訳を示す。1 つのベンチマークにつき、3 つ組の棒グラフが 3 セット並んでいる。3 つ組は、左から順に、フィルタなし、フィルタ機構付き、バス情報を用いたフィルタ機構付きを表す。また、3 つのセットは、左から順に、GPP, PBP, PTBP である。縦軸の正方向はヒット率を、負方向はミス率を表す。ヒット/ミスは、それぞれ、以下の 4 つに分けられている：

- PHT 分岐予測器使用時のヒット/ミス
- Filter フィルタ使用時のヒット/ミス
- BTB BTB ミスにより Untaken と予測したときのヒット/ミス
- RAS return address stack 使用時のヒット/ミス

グラフより、どのベンチマークにおいても、バス情報を用いたフィルタ機構はフィルタ機構よりもフィルタリング率/精度ともに良い。特に gcc においては、RAS, BTB, Filter によってヒットした分岐の割合の合算値が、フィルタ機構付きでは 66.9%だったのに対し、バス情報を用いたフィルタ機構付きでは 75.0%と 8.1%増加した。一方、ミスした場合のそれは、どちらも 2.10%と変化していない。

分岐予測器に対する性能

図 9 において、バス情報を用いたフィルタ機構「なし」のモデルと「あり」のモデルを比較すると分かるように、バス情報を利用しない予測器である GPP では、バス情報を用いたフィルタ機構の効果が見られる。特に、8~32KB の区間では、「あり」のモデルの平均予測ミス率が「なし」のそれを下回っている。

また、ベンチマークごとの性能 (図 10) を見ると、compress を除き、「あり」の予測ヒット率が「なし」のそれを上回っている。特に、go においては、「あり」




図 9 各モデルの予測ミス率
Fig. 9 Misprediction rate of each models.

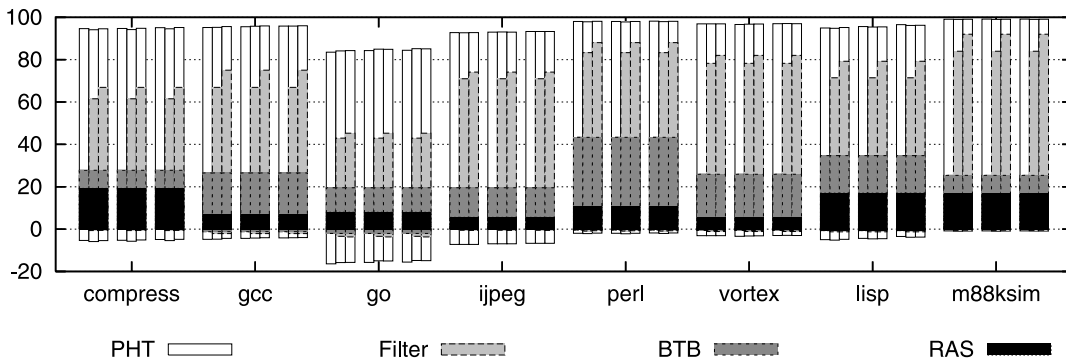


図 10 予測ヒット/ミス率の内訳 (8KB 構成時)
Fig. 10 Breakdown of hit /miss rate with a 8KB hardware budget.




図 11 破壊的競合の割合 (8 KB 構成時)

Fig. 11 Destructive aliasing rate with a 8 KB hardware budget.

が 84.3%、「なし」が 83.6%と 0.7%改善されている。

一方、パス情報を用いたフィルタ機構をパス情報を利用する予測器に適用した場合は、その効果は薄い。PBP は 8~16 KB 構成時、PTBP は 8 KB 構成時においてのみ、「あり」のモデルの平均予測ミス率が「なし」のモデルのそれを下回る。このように効果が薄いのは、フィルタに利用されているものよりも長いパス情報が予測器自体に利用されており、フィルタによる予測ミスの影響が相対的に大きくなるからと考えられる。

ベンチマークごとの性能 (図 10) を見ると、GPP と同様、go における性能向上が強く影響していることが分かる。「あり」の予測ヒット率は、PBP、PTBP がそれぞれ 84.9%、85.1%、「なし」が 84.3%、84.4%と 0.6~0.7%改善されている。

また、すべての予測器において、128 KB 構成時では、フィルタなしのモデルが最も性能が良い。これは、「パス長に対する性能」の項でも述べたように、メモリ量が多くなると競合自体が減り、フィルタによる予測ミスの影響が相対的に大きくなるためである。

破壊的競合の割合

図 11 に、8 KB 構成時の破壊的競合の割合を示す。3 つ組、3 セットの棒グラフは、図 10 と同様、9 つのモデルに対応する。すなわち、3 つ組は、左から順に、フィルタなし、フィルタ機構付き、パス情報を用いたフィルタ機構付きを、3 セットは、左から順に、GPP、PBP、PTBP を表す。縦軸は破壊的競合の割合を表す。

ここで、破壊的競合の割合は、分岐命令のそれではなく、パスのそれを表している点に注意されたい。

たとえば、 $A_3 \rightarrow A_2 \rightarrow A_1 \rightarrow A_0$ というパスと $A_3 \rightarrow A_2 \rightarrow A'_1 \rightarrow A_0$ というパスが PHT の同一エントリを使用したとしよう。その場合、分岐命令のアドレスは同じ (A_0) であるから、分岐命令は競合していない。したがって、2 つのパスに別々のエントリが

割り当てられた場合と予測結果が異なり、かつ、予測ミスしたとしても、破壊的競合とは呼ばない。

一方、上述の例では、分岐命令のアドレスの履歴は異なる (A_1 と A'_1) から、パスは競合している。そのため、別々のエントリが割り当てられた場合と予測結果が異なり、ミスした場合は、破壊的競合と数える。

図 11 より、破壊的競合の割合は、ほとんどのベンチマーク、予測器において、パス情報を用いたフィルタ機構「あり」が最も少ない。特に、go においては、「あり」の割合は、GPP、PBP、PTBP がそれぞれ 10.1%、9.96%、9.82%、「なし」が 11.9%、11.7%、11.6%と 1.7~1.8%減少している。

5. おわりに

本稿では、パス情報を分岐のフィルタリングに利用できる可能性を示した。3.1 節で述べたように、パス長が 4~16 あれば、4~7 割のパスはフィルタリングできる。

また、具体的な実装例としてパス情報を用いたフィルタ機構を提案した。提案手法は、GPP に適用した場合は一定の効果が得られるものの、PBP、PTBP に適用した場合の効果は薄い。今後は、よりフィルタリング率/精度の高い機構の開発が望まれる。

謝辞 本研究の一部は、日本学術振興会科学研究費補助金基盤研究 S (課題番号 16100001)、および 21 世紀 COE プログラム (課題番号 14213201) による。

参考文献

- 1) 安藤秀樹：命令レベル並列処理，chapter 2，コナ社 (2005)。
- 2) Chang, P.Y., Evers, M. and Patt, Y.N.: Improving Branch Prediction Accuracy by Reducing Pattern History Table Interference, *Proc. PACT* (1996)。
- 3) Jiménez, D. and Lin, C.: Dynamic Branch Prediction with Perceptrons, *Proc. 7th Interna-*

tional Symposium High Performance Computer Architecture, Monterrey, NL, Mexico, pp.197-206 (2001).

- 4) Jiménez, D. and Lin, C.: Fast Path-Based Neural Branch Prediction, *Proc. 36th Annual International Symposium Microarchitecture*, San Diego, CA (2003).
- 5) Jiménez, D. and Lin, C.: Piecewise Linear Branch Prediction, *Proc. 32nd International Symposium Computer Architecture*, Madison, Wisconsin (2005).
- 6) McFarling, S.: Combining branch predictors, Wrl technical report tn-36, Digital Equipment Corporation (1993).
- 7) 斎藤史子, 山名早人: BTB のエントリ有無を参照した分岐予測器, *SACIS2004*, 札幌, pp.261-268 (2004).
- 8) 坂和正俊, 田中雅博: ニューロコンピューティング入門, chapter 1-2, 森北出版株式会社 (1997).
- 9) Sprangle, E. and Carmean., D.: Increasing processor performance by implementing deeper pipelines, *Proc. 30th International Symposium Computer Architecture*, Anchorage, Alaska, pp.25-34 (2002).
- 10) 石井康雄, 平木 敬: 実行パス履歴情報を利用した分岐予測手法, *情報処理学会論文誌, コンピューティングシステム*, Vol.47, No.SIG 3 (ACS 13), pp.58-72 (2006).

(平成 18 年 1 月 26 日受付)

(平成 18 年 5 月 3 日採録)



三輪 忍 (正会員)

1977 年生. 2000 年京都大学工学部情報学科卒業. 2002 年同大学大学院情報学研究科通信情報システム専攻修士課程修了. 2005 年同大学院情報学研究科通信情報システム専攻博士後期課程学習認定退学. 同年より京都大学法学研究科助手, 現在に至る. 計算機アーキテクチャ, ニューラルネットの研究に従事. 電子情報通信学会, 人工知能学会, 日本神経回路学会, 計測自動制御学会各会員.



福山 智久 (正会員)

1979 年生. 2005 年京都大学工学部情報学科卒業. 同年より同大学大学院情報学研究科通信情報システム専攻修士課程, 現在に至る. 計算機アーキテクチャの研究に従事.



嶋田 創 (正会員)

1976 年生. 1998 年名古屋大学工学部情報工学科卒業. 2000 年同大学大学院工学研究科情報工学専攻博士前期課程修了. 2004 年名古屋大学博士 (工学). 2004 年名古屋大学電気系 COE 研究員. 2005 年京都大学大学院情報学研究科特任助手. 現在, 京都大学大学院情報学研究科助手. 計算機アーキテクチャの研究に従事.



五島 正裕 (正会員)

1968 年生. 1992 年京都大学工学部情報工学科卒業. 1994 年同大学大学院工学研究科情報工学専攻修士課程修了. 同年より日本学術振興会特別研究員. 1996 年京都大学大学院工学研究科情報工学専攻博士後期課程退学, 同年より同大学工学部助手. 1998 年同大学大学院情報学研究科助手. 2005 年東京大学情報理工学系研究科助教授, 現在に至る. 高性能計算機システムの研究に従事. 博士 (情報学). 2001 年情報処理学会山下記念研究賞, 2002 年同学会論文賞受賞. IEEE 会員.



中島 康彦 (正会員)

1963 年生. 1986 年京都大学工学部情報工学科卒業. 1988 年同大学大学院修士課程修了. 同年富士通 (株) 入社. スーパーコンピュータ VPP シリーズ, 命令エミュレーション, 高速 CMOS 回路設計等に関する研究開発に従事. 工学博士. 1999 年京都大学総合情報メディアセンター助手. 同年同大学大学院経済学研究科助教授, 2002 年より (兼) 科学技術振興事業団さきかけ研究 21 (情報基盤と利用環境). 2006 年奈良先端科学技術大学院大学情報科学研究科教授, 現在に至る. コンピューティング・アーキテクチャに興味を持つ. IEEE, ACM 各会員.



森 眞一郎（正会員）

1963年生．1987年熊本大学工学部電子工学科卒業．1989年九州大学大学院総合理工学研究科情報システム学専攻修士課程修了．1992年同大学院総合理工学研究科情報シ

ステム学専攻博士課程単位取得退学．同年京都大学工学部助手．1995年同助教授．1998年同大学大学院情報学研究科助教授．2006年福井大学大学院工学研究科情報・メディア工学専攻教授．工学博士．並列/分散処理，可視化，計算機アーキテクチャの研究に従事．電子情報通信学会，可視化情報学会，IEEE CS，ACM，EUROGRAPHICS 各会員．



富田 眞治（正会員）

1945年生．1968年京都大学工学部電子工学科卒業．1973年同大学大学院博士課程修了．工学博士．同年京都大学工学部情報工学教室助手．1978年同助教授．1986年九州大学

大学院総合理工学研究科教授，1991年京都大学工学部教授，1998年同大学大学院情報学研究科教授，2006年同大学院情報学研究科長，現在に至る．計算機アーキテクチャ，並列処理システム等に興味を持つ．電子情報通信学会，IEEE，ACM 各会員．平成7年，8年度，10年，11年度本会理事．平成13年，14年度同関西支部長．