

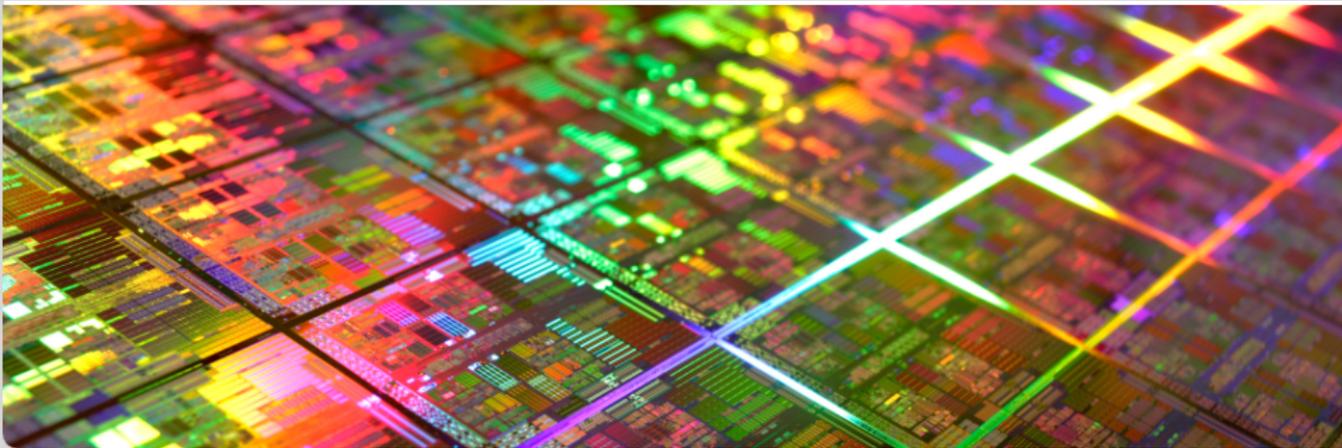
# Vorlesung Rechnerstrukturen im SS 2011

## Sprungvorhersage

David Kramer, Prof. Dr. Wolfgang Karl

Lehrstuhl für Rechnerarchitektur und Parallelverarbeitung

17. Mai 2011



## Bedingte Sprünge

- Problem: Ergebnis der Auswertung erst nach EX-Phase
- Pipeline-Stalling bis Auswertung
- Minimierung des Pipeline-Durchsatzes
- Alternative: Sprungvorhersage
  
- Zwei grundsätzliche Arten von Sprungvorhersage
  - Statische Vorhersage (feste Sprungannahme)
  - Dynamische Sprungvorhersage
  
- Ziel: Umschiffung des Steuerkonflikts durch korrekte Sprungvorhersage
  - Maximierung des Pipeline-Durchsatzes
  - Minimierung von Flush/Wiederanlauf

## Statische Sprungvorhersage

- Keine Vorhersage im eigentlichen Sinn, sondern Definition des Sprungverhaltens:
  - always not taken (i386)
  - always taken (i486)
  - Abhängig von Sprungrichtung (PPC405)
- Sprungvorhersage basiert auf Schleifenannahme
  - Rücksprung in den Schleifenkörper nehmen
  - Aussprung durch Abbruchkriterium nicht nehmen
  - Bei einfachem Modell somit nur Fehlvorhersage für Abbruchkriterium
- Für besten Erfolg Compilerunterstützung notwendig
  - Umformung der hochsprachlichen Schleifen analog zur verwendeten Sprungvorhersage
  - Ggf. Umformulierung von Fallunterscheidungen
  - Anpassung des Programms an Sprungvorhersage

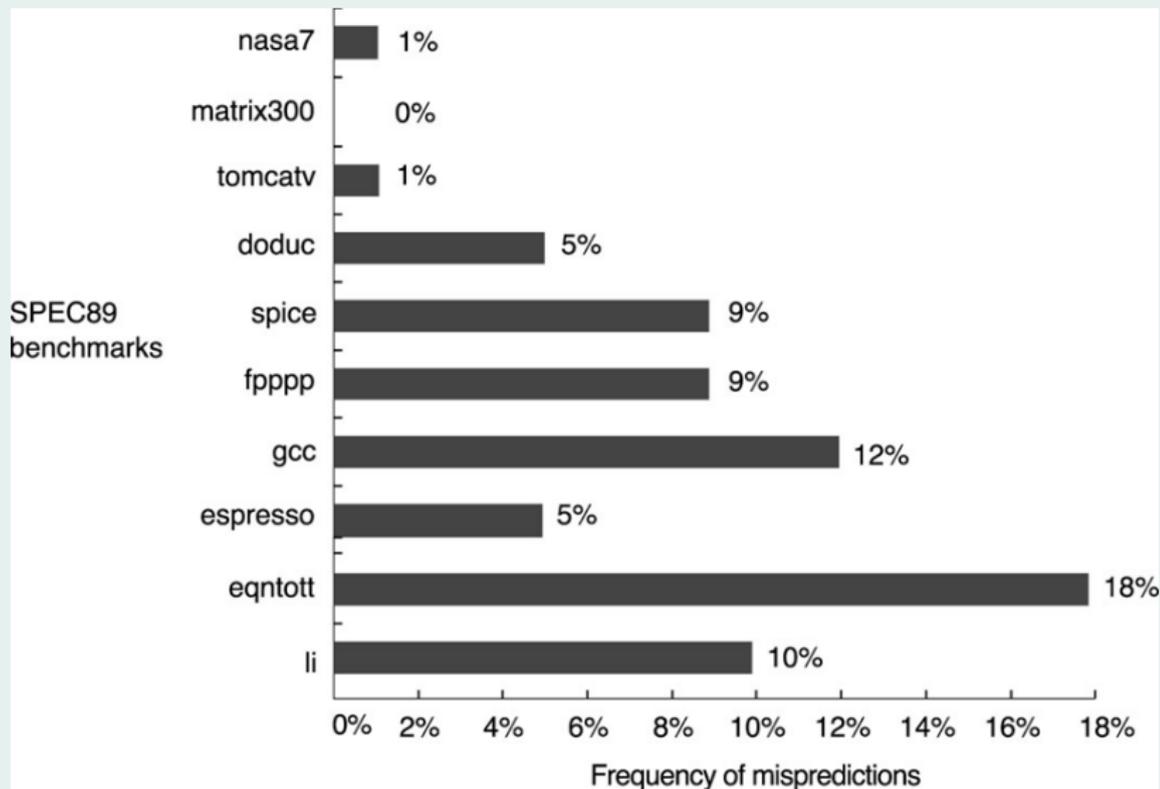
## Dynamische Sprungvorhersage

- Anpassung der Sprungvorhersage an laufendes Programm
- Einführung einer Sprunghistorie
- Etliche Konzepte mit variierender Komplexität
  - 1-Bit-Prädiktor
  - 2-Bit-Prädiktor (Sättigungszähler und Hysteresemodell)
  - Korrelationsprädiktoren
  - Zweistufig adaptive Prädiktoren
  - gshare, gselect
  - Hybridprädiktoren
- Vorhersagegenauigkeit in realen Programmen weit besser als statische Vorhersage
  - typischerweise  $\gg 95\%$
- Aber: Hardwaretechnisch aufwendiger

# Spezifikationsverbesserung (fortge.)

## Beispiel: Vorhersagegenauigkeit

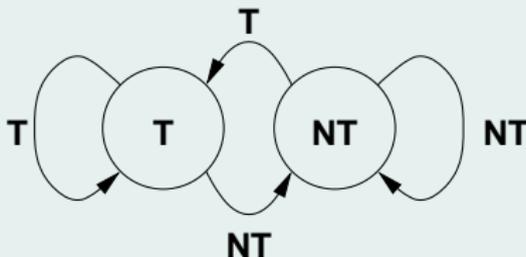
D



2-Bit-Prädiktor, 4096 Einträge

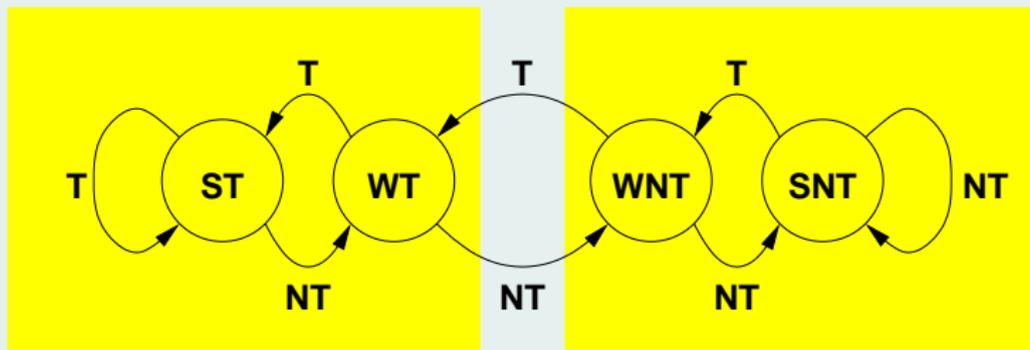
Quelle: Elsevier Science, 2003

## 1-Bit-Prädiktor



- Zustandsautomat mit 2 Zuständen:  
taken (T), not taken (NT)
- Aktueller Zustand definiert Sprungvorhersage
- Zustandsübergang anhand tatsächlichem Sprungverlauf
- daher: Initialisierung entscheidet Anlaufverhalten
- Problem: Kurze Historie
  - Zwei Fehlvorhersagen bei verschachtelten Schleifen:  
Schleifenende und Wiedereintritt

## 2-Bit-Prädiktor mit Sättigungszähler

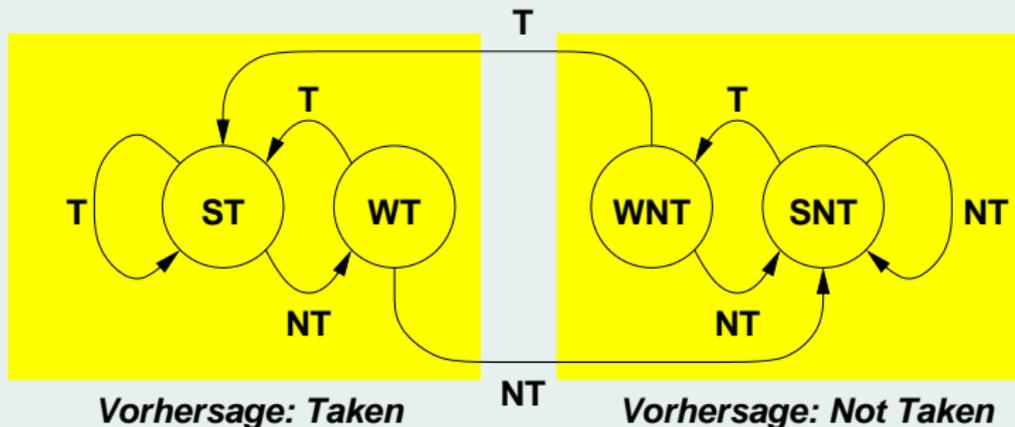


*Vorhersage: Taken*

*Vorhersage: Not Taken*

- Zustandsautomat mit 4 Zuständen: strongly taken (**ST**), weakly taken (**WT**), weakly not taken (**WNT**), strongly not taken (**SNT**)
- Wechsel der Vorhersage erst nach zwei Fehlvorhersagen
- Optimiert Schleifenaustritts- und Wiederanlaufverhalten

## 2-Bit-Prädiktor mit Hysterese



- Zustandsautomat mit 4 Zuständen: strongly taken (**ST**), weakly taken (**WT**), weakly not taken (**WNT**), strongly not taken (**SNT**)
- Wechsel der Vorhersage erst nach zwei Fehlvorhersagen
- Aggressiveres Umschaltverhalten, vermeidet „Flattern“ zwischen Weakly-Zuständen

## n-Bit-Prädiktoren: Diskussion

- Qualität der 2-Bit-Prädiktoren variiert je nach Anwendungsgebiet
- Sehr gute Leistung bei numerischen Problemen (große Schleifen, kaum if/then/else-Konstrukte)
- Anzahl Fehlspekulationen bei allgemeinen Anwendungen höher: kurze Schleifen, Programmcode dominiert von Fallunterscheidungen
- Fehlspekulation bei SPEC89: zwischen 1% und 18% (gcc: 12%)
- Weitere Vergrößerung bringt praktisch keine Verbesserung der Sprungvorhersage
- Ursache: Korrelationen
  - if/then/else-Konstrukte

## Problemfall: Korrelation

Code:

```
    if (d==0)          /* Sprung 1 */
        d=1;
    if (d==1)          /* Sprung 2 */
        ...
```

| d vor S1 | d==0? | S1 | d vor S2 | d==1? | S2 |
|----------|-------|----|----------|-------|----|
| 0        | Ja    | NT | 1        | Ja    | NT |
| 1        | Nein  | T  | 1        | Ja    | NT |
| 2        | Nein  | T  | 2        | Nein  | T  |

- Beispiel zeigt korrelierten Sprung ( $S1 \sim S2$ ) mit 1-Bit-Vorhersage
- Korrelationsinformation nicht von n-Bit-Prädiktoren auswertbar
- Keine Kenntnis über Sprungumgebung

## Beispiel

Sprungverlauf eines Programms beim viermaligen Durchlaufen einer Endlosschleife.

| Sprung 1<br>beqi R1,2 | Sprung 2<br>beqi R1,2 | Sprung 3<br>JMP start | Sprung 4<br>JMP start |
|-----------------------|-----------------------|-----------------------|-----------------------|
| NT (R1=1)             | T (R1=2)              | -                     | T                     |
| T (R1=2)              | NT (R1=0)             | T                     | -                     |
| NT (R1=1)             | T (R1=2)              | -                     | T                     |
| T (R1=2)              | NT (R1=0)             | T                     | -                     |

Analyse: Sprünge 1 und 2 sind voneinander abhängig!

# Sprungvorhersagebeispiel (forts.)

## Leistung des 1-Bit-Prädiktors

Es werden **6** Fehlannahmen gemacht:

| Sprung 1   |           |        | Sprung 2   |           |        |
|------------|-----------|--------|------------|-----------|--------|
| Prädiktion | Sprung    | P. neu | Prädiktion | Sprung    | P. neu |
| NT         | <b>NT</b> | NT     | T          | <b>T</b>  | T      |
| NT         | <b>T</b>  | T      | T          | <b>NT</b> | NT     |
| T          | <b>NT</b> | NT     | NT         | <b>T</b>  | T      |
| NT         | <b>T</b>  | T      | T          | <b>NT</b> | NT     |

## Leistung des 2-Bit-Prädiktors

Es werden **4** Fehlannahmen gemacht:

| Sprung 1   |           |        | Sprung 2   |           |        |
|------------|-----------|--------|------------|-----------|--------|
| Prädiktion | Sprung    | P. neu | Prädiktion | Sprung    | P. neu |
| WNT        | <b>NT</b> | SNT    | WT         | <b>T</b>  | ST     |
| SNT        | <b>T</b>  | WNT    | ST         | <b>NT</b> | WT     |
| WNT        | <b>NT</b> | SNT    | WT         | <b>T</b>  | ST     |
| SNT        | <b>T</b>  | WNT    | ST         | <b>NT</b> | WT     |

- n-Bit-Prädiktoren sind sprungzentrisch
  - Keine Betrachtung des umgebenden Sprungverlaufs
- Einführung von Korrelationsprädiktoren Anfang der 1990er-Jahre

## Korrelationsprädiktoren

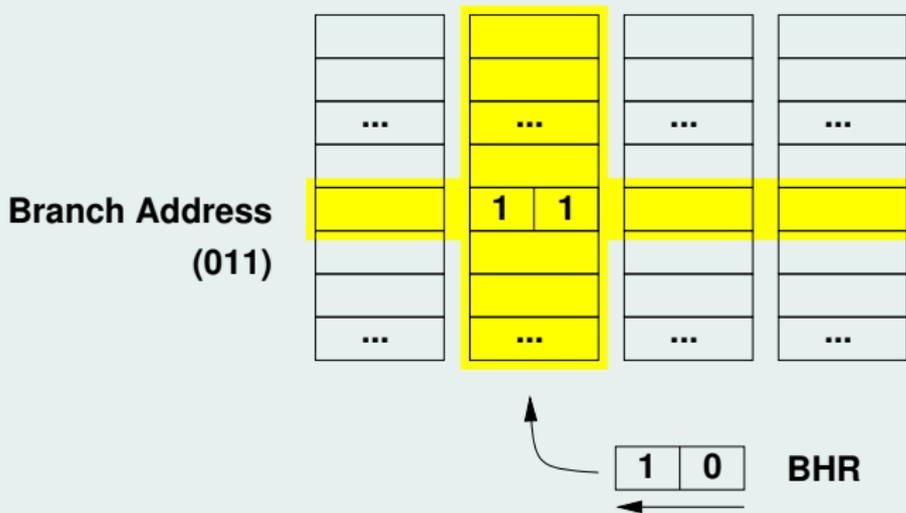
- Pan et al., 1992: (m,n)-Korrelationsprädiktoren (*correlation-based predictors, correlating predictors*)
- Yeh und Patt, 1993: Zweistufig adaptive Prädiktoren (*bi-level adaptive predictors*)
- McFarling, 1994: gselect und gshare
- McFarling, 1993: Hybridprädiktoren

## (m,n)-Korrelationsprädiktoren

- Einführung einer m Sprünge umfassenden Historie
- Speicherung in Sprungverlaufsregister bzw. Branch History Register (BHR)
- BHR ist m-Bit breites Schieberegister, hält den Ausgang der letzten m Sprünge (1 - taken, 0 - not taken)
- Auswahl eines n-Bit-Prädiktors aus Sprungverlaufstabelle (Pattern History Table, PHT) anhand von Sprungadresse und BHR
- (Teil der) Sprungadresse selektiert Reihe
- BHR selektiert eine von  $2^m$  Spalten
- Ausgewähltes Speicherfeld enthält n-Bit-Prädiktor

## (2,2)-Korrelationsprädiktor

### Pattern History Tables



## Leistung des (1,1)-Korrelationsprädiktors

Es werden **keine** Fehlannahmen gemacht:

| Sprung 1        |        |        | Sprung 2        |        |        |
|-----------------|--------|--------|-----------------|--------|--------|
| Prädiktion      | Sprung | P. neu | Prädiktion      | Sprung | P. neu |
| ( <b>NT</b> ,T) | NT     | (NT,T) | ( <b>T</b> ,NT) | T      | (T,NT) |
| (NT, <b>T</b> ) | T      | (NT,T) | (T, <b>NT</b> ) | NT     | (T,NT) |
| ( <b>NT</b> ,T) | NT     | (NT,T) | ( <b>T</b> ,NT) | T      | (T,NT) |
| (NT, <b>T</b> ) | T      | (NT,T) | (T, <b>NT</b> ) | NT     | (T,NT) |

Auswahl des (lokalen) Prädiktors erfolgt nach Ausgang des (globalen) letzten Sprungs (1-Bit BHR)

## Sprungvorhersagealternativen

- Prädikative Ausführung
  - Parallele Ausführung von Entscheidungspfaden
  - Kopplung der Ergebnisse an Prädikatregister
  - Bedingungstest und Verwerfen der Fehlergebnisse
  - Beispiel: Intel IA64
  - Balancierte Pfade erforderlich
  - Hardwareaufwand (Einheiten, Register)
- Bedingte Ausführung
  - Kopplung der Befehlsausführung an Bedingung
  - Umwandlung des Befehls in NOP, falls nicht erfüllt
  - Günstig in der Implementierung
  - Compilerunterstützung
  - Beispiel: ARM

| <b>Sprungvorhersagetechnik</b>   | <b>Beispielarchitekturen</b>  |
|--|---|
| keine Sprungvorhersage   | Intel i8086, praktisch alle 8- & 16-Bit-Prozessoren sowie Mikrocontroller                     |
| Statische Verfahren<br>always not taken<br>always taken<br>Rücksprung genommen, Aus sprung nicht | Intel i386<br>Intel i486, Sun SuperSPARC<br>HP PA-7x00, PPC405                                |
| Dynamische Verfahren<br>1-Bit-Prädiktor<br>2-Bit-Prädiktor                                       | DEC Alpha 21064, AMD K5<br>PPC604, MIPS R10000, Cyrix 6x86,<br>M2, NexGen 586, Motorola 68060 |
| Bi-level Adaptive<br>gshare  | Intel Pentium Pro, Pentium II, AMD K6<br>Intel Pentium III, AMD Athlon                        |
| Hybridprädiktoren  | DEC Alpha 21264   |
| Prädikation  | Intel IA-64, ARM, TI TMS320C6201,<br>weitere DSPs   |
| Mehrfadausführung  | IBM 360/91, IBM 3090 (Großrechner)  |

## Zusammenfassung

- Sprungzielcache (BTAC/BTB) zur frühestmöglichen Sprung- und Sprungzielerkennung
- Statische Vorhersagemethoden
  - Vorgabe der Sprungannahme, ggf. in Abhängigkeit der Sprungrichtung (always taken, always not taken, reverse taken/forward not taken)
  - Compilerunterstützung
- Dynamische Vorhersagemethoden
  - Berücksichtigung der Sprung-Vorgeschichte (BHT)
  - Miteinbezug der globalen Sprunghistorie (BHR)
  - Hoher Hardwareaufwand, aber auch hohe Genauigkeit
- Sprungvermeidung
  - Prädikative Ausführung
  - Bedingte Ausführung

- Brinkschulte/Ungerer:  
Mikrocontroller und Mikroprozessoren  
Springer, 2. Auflage, 2007
- Tse-Yu Yeh, Yale N. Patt:  
Two-level adaptive training branch prediction  
ACM, 1991

## Was ist ein Prozessorarchitektursimulator?

- Ein Werkzeug, welches das Verhalten eines Prozessors nachahmt.



## Warum werden Simulatoren verwendet?

- Simulatoren beschleunigen die Exploration eines Entwurfraumes
- Ermöglichen die parallele Entwicklung von Hard- und Software
- Im Vergleich zu HW-Prototypen: Leichte Erweiterbarkeit

## Welche Arten von HW-Simulatoren gibt es?

- Funktionale Simulatoren
  - Kein Zeitmodell
  - Erzeugung von Statistiken
  - Trace-Driven
  - Execution-Driven
    - Emulation
    - Direct Execution
- Leistungs-/Mikroarchitektur-Simulatoren
  - Simulation von komplexen Mikroarchitekturen
  - Cycle timer - Zyklengenau
- Full-System-Simulation
  - Simulation eines vollständigen Systems (z.B. Prozessor inkl. Betriebssystem und Peripherie)

## Computer Architecture Research Test Bed

- Compiler, Assembler, Linker, Libraries und Simulatoren
- Zielarchitektur: SimpleScalar PISA (RISC-Format)
- angepaßte GNU Werkzeuge: gcc, binutils
- Kommandozeilen-basiert

## Simulatoren

- sim-fast / sim-safe (einfach funktional)
- sim-profile (Erstellung von Statistiken)
- sim-cache / sim-cheetah (Cache-Simulation)
- sim-bpred (Prädiktor-Simulation)
- sim-outorder (Zyklengenaue Simulation, OoOE-Engine)

## Usage

- Übersetzung:

```
sslittle-na-sstrix-gcc -o output input.c
```

- Ausführung:

```
sim-bpred [-sim opts] program [-program_opts]
```

## Options `sim-bpred` (Auswahl)

```
-bpred <string> # Default bimod  
# predictor type {nottaken|taken|bimod|2lev|comb}  
-bpred:bimod <int> # 2048  
# bimodal predictor config (<table size>)  
-bpred:2lev <int list...> # 1 1024 8 0  
# 2-level predictor config  
# (<l1size> <l2size> <hist_size> <xor>)
```