# 4. Spekulativno izvršavanje

Pod spekulativnim izvršanjem podrazumevamo izvršavanje operacije unapred, uprkos tome što možda nije uopšte trebala da se izvrši. Pritom, postoji neka verovatnoća da će ta operacija, sa datim ulaznim podacima, zaista biti neophodna. Ovakvo izvršavanje unapred može biti korisno za skraćivanje prosečnog vremena izvršavanja programa kod paralelnih mašina. Ako mašina ima dovoljno resursa, spekulativno izvršavanje ne mora da uspori izvršavanje programskog kôda za bilo koji dinamički trag izvršavanja, jer ima dovoljno resursa za najbrže izvršavanje i onog dela kôda koji nije spekulativan. Međutim, ukoliko je operacija zaista trebalo da se obavi, ona se spekulativnim izvršavanjem obavila ranije. Zbog toga, sve operacije koje zavise po podacima od te operacije (bilo direktno ili ne) mogu ranije da se izvršavaju. Dakle, njeno ranije izvršavanje omogućava drugim, ili takođe spekulativnim operacijama ili pak nespekulativnim operacijama da se ranije izvrše.

Ako se pokaže da je operacija urađena unapred nepotrebno, neophodno je poništiti sve efekte spekulativno izvršene operacije. To se odnosi na generisani rezultat, ali i na eventualne izuzetke. Naravno, sve druge operacije koje su koristile rezultate takve spekulativne operacije su bile takođe spekulativne, pa je potrebno poništiti i njihove efekte. Pod rezultatima spekulativne operacije se podrazumevaju rezultat operacije i/ili vrednost odgovarajućeg bita u procesorskoj statusnoj reči (izračunati flegovi kod skokova) nastali kao posledica izvršavanja spekulativne operacije.

Postoje dve kategorije spekulativnog izvršavanja: **spekulativno izvršavanje po kontroli** i **spekulativno izvršavanje po podacima**. ***Spekulativno izvršavanje po kontroli*** podrazumeva da se na osnovu pretpostavke da će nekoliko predikata (flegova), koji određuju tok kontrole, imati neke vrednosti, obavimo operacije koje su originalno trebale da se izvrše posle jednog ili više grananja kasnije. Spekulativno izvršavanje po kontroli može da se uradi tokom prevođenja ili tokom izvršavanja. Mora se obaviti poništavanje svih efekata spekulativnog izvršavanja po kontroli kada se utvrdi da spekulativna operacija nije trebalo da se izvrši. Neophodno je dakle poništiti i rezultat(e) operacija i eventualno nastale izuzetke zbog obavljanja operacija koje nisu ni trebale da se obave na osnovu toka kontrole.

## 4.1. Predikatsko izvršavanje

Jedna od tehnika za poništavanje efekata spekulativnog izvršavanja po kontroli je da se uz spekulativnu operaciju pridruži i predikat kojim se definiše pod kojim logičkim uslovima se prihvata rezultat operacije{PS 91}{SM 92}{MA 92}{MJ 98A}. Predikat se formira tako da definiše neophodan ishod (vrednosti flegova) redom svih grananja koje je spekulativna operacija prešla prilikom selidbe na gore, sa ciljem što ranijeg izvršavanja. Te selidbe se obavljaju prilikom optimizacije u vreme prevođenja. Najjednostavniji način predstavljanja je pomoću niza bita čija je dužina jednaka broju uslovnih grananja koje je spekulativna operacija prešla prilikom selidbe na gore, a vrednosti bita odgovaraju potrebnim ishodima skoka. Naravno, mora da postoji u nekoj formi i podatak da li je operacija uopšte spekulativna i koliko je spekulativnih bita validno (preko koliko je grananja preseljena operacija).

Ako se tokom izvršavanja dogodi da je vrednost predikata takva da na osnovu toka izvršavanja treba poništiti efekte spekulativno urađene operacije, odmah se oslobađaju resursi i svi efekti takvih operacije se poništavaju. Takvo izvršavanje se naziva **predikatskim izvršavanjem**, kao jedna od vrsta spekulativnog izvršavanja po kontroli {MA 92}. U anglosaksonskoj literaturi se koristi termin *predication*, a alternativni naziv je *If conversion*. Ovim postupkom se efektivno eliminišu kontrolne zavisnosti operacija od bliskih grananja, jer se operacija može izvršiti pre određivanja jednog ili više predikata (flegova) za grananje, koji su originalno prethodili operaciji na tragu.

Dakle, kod predikatskog grananja se u vreme prevođenja, tokom optimizacije, odredi koje operacije je potrebno seliti preko grananja na gore, da bi se dobio što paralelniji kod. Zatim se te operacije presele preko najviše n grananja na gore, gde je n broj bita predviđen u hardveru za predikate. Operacije zavisne po podacima od navedene spekulativne operacije dobijaju isti predikat, ili predikat sa još većim brojem bita predikata (ali manji ili jednak n), zavisno od toga da li su prešle još neko(a) grananje na gore. U vreme izvršavanja, kada se izračunavaju predikati, radi se poređenje sa svim predviđenim bitima predikata u vreme prevođenja i odbacuju operacije za koje ne postoji slaganje na makar i jednom bitu predikata. Ovo je kombinovana tehnika u kojoj se planiranje selidbi na gore preko grananja i definisanje broja i vrednosti predikata radi u vreme prevođenja, a u izvršavanju se samo proverava da li se pretpostavka o toku kontrole iz vremena prevođenja za spekulativnu operaciju poklopila sa onim što se dogodilo u vreme izvršavanja. Ta pretpostavka je ograničena na broj bita predikata koji je validan u spekulativnoj operaciji.

Treba napomenuti da na ovaj način mogu da se sele preko grananja na gore operacije iz obe grane, naravno sa drugačijim predikatima. Time se grananje može potpuno eliminisati i zameniti bitima predikata za operacije iz obe grane. Najčešći način realizacije predikatskog izvršavanja u procesorima je upravo bio sa samo jednim bitom predikata. U tom slučaju su se npr. obe grane IF-THEN-ELSE strukture i bazični blokovi pre i posle te strukture mogu izvršavati i optimizovati kao jedan bazični blok, a operacije iz obe grane će se izvršavati do trenutka kada se odredi uslov grananja, pa će na osnovu izračunatog uslova da se odbace one izvršene operacije koje imaju pogrešan predikat u vreme izvršavanja. One operacije raspoređene u vreme prevođenja posle ciklusa izračunavanja bita predikata koji imaju različitu vrednost predikata od izračunate se neće ni obavljati. Zbog obavljanja viška operacija u **svakom izvršavanju** i naglog povećanja procenta instrukcija koje se odbacuju kada se povećava broj bita predikata, predikatsko izvršavanje dozvoljava preklapanje samo malog broja bazičnih blokova u postupcima paralelizacije. U slučaju opisanom u ovom pasusu, broj bazičnih blokova čije su operacije potpuno preklopljene je limitiran na 4. Cena koja se plaća predikatskim izvršavanjem je, dakle, povećan broj operacija koje se odbacuju, ali nema nikakve potrebe da se radi vraćanje na neko ranije stanje, već se pojedinačne operacije hardverski odbacuju.

## 4.2. Dinamička predikcija grananja

Druga tehnika spekulativnog izvršavanja po kontroli je da se spekulativno izvršavaju operacije duž samo jednog pretpostavljenog dinamičkog traga. Tada se pamti samo dinamički predviđen niz predikata koji se dopunjava sa svakom novom predikcijom grananja. Tako određen pretpostavljeni trag u sebi sadrži predikate za sve operacije predviđene za izvršavanje. U trenucima izračunavanja ishoda uslovnih grananja, ispituje

se da li je ishod skoka u skladu sa odgovarajućim predviđenim bitom na tom zajedničkom pretpostavljenom tragu. Ako jeste, nastavlja se spekulativno dohvatanje instrukcija i skokova po predviđenom tragu i njihovo izvršavanje. Ako se utvrdi da je došlo do greške u predikciji (predviđanju nekog grananja na tragu), moraju se poništiti efekti svih operacija čije se izvršavanje zasnivalo na toj pogrešnoj pretpostavci. Ključna komponenta u ovom slučaju je prediktor grananja, a pojedinačne operacije uopšte nemaju sopstvene predikate kao kod predikatskog izvršavanja. Naravno, za sve operacije se nekako mora pamtiti kom bazičnom bloku na tragu su pripadali, kako bi se u slučaju greške u predviđanju mogao uraditi oporavak, a to će detaljnije biti objašnjeno na primeru superskalarnih procesora.

Kod dinamičke predikcije, moguće je uspostaviti takav način rada procesora da se tokom izvršavanja paralelizuju operacije iz velikog broja susednih bazičnih blokova, čime se potencijalno postiže veći paralelizam nego kod predikatskog izvršavanja. Naravno, to ima smisla samo ako je verovatnoća pogađanja dinamičkog prediktora grananja blizu 100%.

U obe navedene tehnike se eliminišu kontrolne zavisnosti ako su pogođena pretpostavljena grananja. U slučaju predikatskog izvršavanja, predviđanje je u vreme prevođenja i na nivou pojedinih operacija se u vreme izvršavanja utvrđuje da li su trebale da se izvršavaju. Cena spekulativnog izvršavanja u ovom slučaju je **odbacivanje pojedinačnih operacija** kojima se ne poklapaju predikat(i) pretpostavljen u vreme prevođenja i predikat(i) dobijeni u vreme izvršavanja. U slučaju dinamičke predikcije, dokle god se pogađa sa dinamičkim prediktorom grananja, ne plaća se nikakva cena za spekulativno izvršavanje. Međutim, kada se desi da se pogreši u predikciji, moraju se nekako izdvojiti operacije koje su ispravno urađene i odbaciti sve operacije koje nisu trebale da se urade i poništiti svi nihovi efekti (rezultati, flegovi i eventualni izuzeci). Tek nakon toga može da se nastavi sa predikcijom i spekulativnim izvršavanjem po kontroli po novom dinamički predviđenom tragu.

## 4.3. Spekulativno izvršavanje po podacima

***Spekulativno izvršavanje po podacima*** podrazumeva da se mogu pretpostaviti ulazni podatak ili podaci za neku operaciju i da na osnovu toga unapred obavimo tu operaciju. Naknadno otkrivena greška u pretpostavci o ulaznim podacima zahteva poništenje efekata te operacije. Razlog za spekulativno izvršavanje po podacima je pokušaj eliminacije direktne prave zavisnosti po podacima, kada se može predvideti rezultat operacije od koje neka operacija zavisi, odnosno argument zavisne operacije. U realnosti, ovakvo spekulativno izvršavanje može se najčešće uraditi kada nije izvesno da li zavisnosti po podacima postoje ili ne. Ukoliko zavisnosti ne postoje, spekulativnim izvršavanjem se postiže ranije izvršavanje operacije, jer se koristi ranije izračunata (stara) vrednost iz lokacije. Ukoliko zavisnost postoji, tada se operacija ponovo obavlja sa novom vrednošću, ali sada sa validnim ulaznim podacima, dakle ne-spekulativno. Naravno, efekat prethodno izvršene spekulativno operacije nad pogrešnim argumentom(ima) se tada mora poništiti.

Spekulativno izvršavanje po podacima može ubrzati izvršavanje naročito kada se tokom prevođenja, u nekim slučajevima, ne može sa sigurnošću utvrditi da li neke zavisnosti po podacima postoje ili ne. Bez spekulativnog izvršavanja se mora pretpostaviti da zavisnosti postoje, kako bi se garantovala korektnost kôda. Kako će kasnije biti

pokazano, zavisnosti po podacima kod programskih petlji i pokazivači su najčešći uzročnici pojava relacija između operacija za koje se, u toku prevođenja, ne može dati definitivan odgovor o postojanju prave zavisnosti po podacima. Pored slučaja sa zavisnostima po podacima za koje sa sigurnošću ne možemo da utvrdimo u vreme prevođenja da li postoje ili ne, spekulativno izvršavanje po podacima se može raditi i tamo gde su pouzdano definisane zavisnosti po podacima. Navedimo primer:

Ako se negde na kritičnom putu u grafu zavisnosti po podacima nalazi podatak koji u veoma visokom procentu slučajeva ima istu vrednost, spekulativno izvršavanje po podacima dovodi do toga da na osnovu pretpostavljene vrednosti efektivno obrišemo granu vezanu za taj podatak na kritičnom putu! Tada operacija na kritičnom putu koja je zavisila od tog podatka može da postane (uslovno) slobodna na vrhu – data ready, na osnovu pretpostavljanja vrednosti podatka. Ako je operacija koja generiše "predvidiv podatak" još negde na sredini kritičnog puta, to može značajno da ubrza izvršavanje i da paralelizuje izračunavanje obe "polovine" kritičnog puta. Kada se izračuna operacija kojoj je rezultat (podatak) pretpostavljen, poređenjem pretpostavke i izračunatog rezultata se dobijaju dva ishoda:

a. Izračunat rezultat je jednak pretpostavljenom – tada smo znatno ubrzali izvršavanje i prihvatamo rezultate svih spekulativno izvršenih operacija
b. Izračunat rezultat nije jednak pretpostavljenom – tada se moraju poništiti svi efekti operacija izvršavanih pod pretpostavkom da je podatak bio poznat (predviđen), jer operacija koja je pretpostavkom o vrednosti argumenta bila (uslovno) slobodna na vrhu – data ready, bila je data ready pod pogrešnom pretpostavkom,

Kao rezime, nameće se pitanje otkuda tako agresivne tehnike optimizacije kôda kod kojih promašaj u predikciji dovodi do značajnog rasipanja resursa. Pokazalo se da je minijaturizacijom vrlo brzo postignut paralelizam u procesorima (broj mašinskih resursa različitih tipova kako je bilo navedeno u *List Scheduling*-u) koji je veći nego paralelizam na instrukcijskom nivou u grafu zavisnosti po podacima kod prosečnog programa. Samim tim se postavilo pitanje: čime uposliti slobodne resurse. Kao prirodno rešenje se nametnulo spekulativno izvršavanje.

Kontrolne zavisnosti su zahtevale da se neka operacija ne može izvršiti dok se na uslovnom grananju ne odredi da će tok izvršavanja sigurno obuhvatiti tu operaciju. Spekulativno izvršavanje po kontroli omogućava ranije izvršavanje instrukcija kojim se efektivno eliminišu kontrolne zavisnosti. Ukoliko je zaista trebalo da se izvrši takva operacija, eliminacijom kontrolne zavisnosti se ubrzava izvršavanje. Spekulativno izvršavanje po podacima omogućava teoretski da se eliminišu zavisnosti po podacima, ako se mogu predvideti argumenti. Vrlo retko je u praksi moguće sa značajnijom verovatnoćom predviđati argumente, osim ako nije u pitanju neka ranije izračunata vrednost za koju se pretpostavlja da je neće promeniti operacije koje mogu, a ne moraju, da je promene. Ako se pretpostavi da će zbog prirode zavisnosti, vrednost promenljive sa malom verovatnoćom biti menjana, korisno je uvesti spekulativno izvršavanje po podacima. Tada efektivno eliminišemo zavisnosti po podacima, ukoliko se stara vrednost ne promeni. Za sada, u komercijalnim procesorima se uglavnom ne koristi spekulativnost po podacima, izuzev kod EPIC mašina, kao što će biti kasnije opisano. Međutim, veoma često se koristi spekulativnost po kontroli. U izvesnom smislu, spekulativnost po kontroli je specijalan slučaj spekulativnosti po podacima, gde je podatak boolean - flag koji određuje tok izvršavanja programa.

## 4.4. Eliminacija kontrolnih zavisnosti

Više autora je realizovalo eksperimente {WA 91}{LW 92} kojima je analizirali paralelizam u kôdu koji se može postići potpunom eliminacijom kontrolnih zavisnosti. U tom slučaju ostaju samo direktne prave zavisnosti po podacima. Rezultati simulacija ukazuju da je prosečan maksimalan paralelizam, zavisno od tipa programskog kôda koji je analiziran, bio u opsegu između 10 i 100. Ovaj nivo paralelizma je izuzetno privlačan, s obzirom da je znatno teže efikasno iskoristiti paralelizam na višem nivou, na nivou procesa {MJ 99}.

Kontrolnu zavisnost je moguće eliminisati na nekoliko različitih načina. Zbog kompletnog uvida, na ovom mestu će se razmatrati i rešenja koja nisu striktno vezana samo za model instrukcijskog nivoa paralelizma, već i za implementaciju.

Vrlo često se limitira dubina do koje je dozvoljeno spekulativno izvršavanje instrukcija po kontroli. Dubina spekulativnog izvršavanja se najčešće definiše kao broj uslovnih grananja preko kojih je operacija spekulativno prebačena na gore prilikom eliminacije kontrolnih zavisnosti. Ta dubina može se, ali ne mora, ograničavati u postupku eliminacije kontrolnih zavisnosti tokom prevođenja. Ako se ograniči, smanjuje se broj operacija koje se mogu izvršiti, a da se nakon toga njihov rezultat ne koristi zbog izvršavanja dinamičkog traga koji ne obuhvata tu operaciju. Na žalost, takvo ograničenje smanjuje mogućnost paralelizacije.

Slična logika se primenjuje i kod metoda eliminacije kontrolnih zavisnosti u toku izvršavanja (run-time dinamička predikcija grananja). Tada se ograničava broj predviđenih uslovnih grananja za koje nije još razrešeno da li su dobro predviđena tokom izvršavanja. U implementaciji run-time metoda eliminacije kontrolnih zavisnosti, u hardveru na nekom mestu mogu da postoje tag-ovi, u kojima su zapisani pretpostavljeni ishodi grananja pod kojim rezultat operacije postaje validan. Kako se u hardveru mora odrediti maksimalna dužina tag-a, postoje hardverska ograničenja dužine predikata za grananje pridruženog spekulativnoj instrukciji, a samim tim i maksimalan broj grananja preko kojih se operacija može prebaciti u cilju spekulativnog izvršavanja.

### 4.4.1. Eliminacija kontrolnih zavisnosti prilikom prevođenja bez predikatskog izvršavanja (compile time)

#### 4.4.1.1. Operacije koje ne mogu da generišu izuzetak

Transformacija kojom je operacija iz jedne grane seljena preko uslovnih grananja na gore, kada nije postojala operacija identična toj operaciji slobodna na vrhu u drugoj grani, mogla se obaviti samo ako je rezultat operacije bio mrtav u drugoj grani. Poštujući strogo definiciju spekulativnog izvršavanja, ova transformacija je specijalan slučaj spekulativnog izvršavanja po kontroli. Takva konstatacija važi, jer se izračunati rezultat koristi samo u jednoj od grana, a rezultat nije potreban u drugoj grani.

Kako je u ovom slučaju spekulativnog izvršavanja po kontroli eliminisan rezultat operacije, kada je operacija nepotrebno izvršena? Pošto je rezultat mrtav u drugoj grani, automatski se poništava rezultat operacije kada kontrola toka prolazi kroz drugu granu. Ovo važi samo za operacije koje ne mogu da generišu izuzetak. Ako operacija može da generiše exception, treba poništiti efekte eventualnog izuzetka (exception) koji bi se

mogao dogoditi prilikom izvođenja te operacije, kada bi tok kontrole bio takav da nije trebalo ni da se prođe tom granom. Osim toga, potrebno je generisati izuzetak bar približno na mestu gde je operacija originalno bila, u slučajevima da je izuzetak trebao da se dogodi. Detalje kako je realizovan tzv. precizni izuzetak (precise exception) će biti razrađeni u delu knjige kojom su opisane VLIW (EPIC) mašine. Suština je da se samo predikatskim izvršavanjem može rešiti problem izuzetaka.

Poništavanjem uticaja izuzetaka se nismo detaljnije bavili kada smo razmatrali osnovne selidbe operacija, kada je operacija seljena samo iz jedne grane preko grananja na gore. To smo činili zbog pojednostavljivanja razmatranja. U daljem tekstu se razmatra kako se može realizovati spekulativno izvršavanje po kontroli bez dodatnog hardvera koje zahteva predikatsko izvršavanje, ali **samo za operacije koje ne mogu da generišu izuzetak**.

U slučaju da je rezultat živ u drugoj grani, spekulativno izvršavanje (selidba preko grananja na gore) bi dovodilo do prepisivanja ranijeg rezultata i efekta sličnog antizavisnosti, jer stari rezultat nije pročitan, a selidbom je prepisan novom vrednošću. Zbog analogije sa antizavisnošću, ovaj hazard tipa upis pre čitanja nastao spekulativnim prebacivanjem operacije preko uslovnih grananja na gore se još naziva i **uslovnom antizavisnošću** {PJ 96}. U daljem tekstu će se pod **spekulativnom selidbom operacije preko uslovnih grananja na gore** podrazumevati slučaj kada postoji uslovna antizavisnost {JP 92}.

Na osnovu analogije sa antizavisnošću, nameće se ideja da se uradi preimenovanje promenljive u koju se upisuje pri ovakvom spekulativnom izvršavanju. Takvim preimenovanjem se automatski generiše promenljiva mrtva u drugoj grani, ali reference (čitanja) te promenljive u grani iz koje je izvučena operacija moraju takođe da se preimenuju. Ukoliko u grani postoji ponovni upis u originalnu promenljivu, preimenovanje referenci se obavlja samo do tačke novog upisa. Preimenovanje kod selidbe preko grananja na gore se može posmatrati kao generisanje rezultata operacije koji je mrtav u drugoj grani, kako bi se mogla primeniti osnovna selidba operacija ranije nazvana: ***Selidba operacije preko grananja na gore, kada nema identične operacije slobodne na vrhu u drugoj grani.***

Da bi preimenovanje bilo korektno i u slučaju ponovnog objedinjavanja toka kontrole, zbog spojeva, mora se sprovesti ponovno stapanje nepreimenovane i preimenovane vrednosti. Na taj način se u trenutku spajanja ponovo javljaju iste promenljive. Da bi se u primeru jasno naznačilo da su neki rezultati živi u granama, u primeru su napisane operacije u kojima se sa desne strane izraza nalazi jedan označeni argument. Naravno da i dalje moraju da se poštuju sve prave zavisnosti po podacima. Motivi za izvlačenje operacije pre grananja zavise od algoritma optimizacije, a na ovom mestu je ideja samo da se prikažu osnovne transformacije ovakvog spekulativnog izvršavanja po kontroli i pokaže njihova ispravnost. Preimenovanje i stapanje, kojim se mogu objasniti osnovne transformacije programskog kôda su ilustrovani na Sl. 4.1.

Stapanje se obavlja tako što se, u grani iz koje je preseljena operacija na gore, originalnoj promenljivoj dodeli vrednosti preimenovane (nove) promenljive. Dodatna operacija je nazvana **kompenzacionom operacijom tipa 1**. Ovo dodeljivanje može da se uradi u bilo kom delu grane. Dakle, kompenzaciona operacija tipa 1 je slobodna i na vrhu i na dnu bazičnog bloka iz koga je izvučena operacija, jer se u grani koriste preimenovane

vrednosti argumenata. Zato je moguće kompenzacionu operaciju tipa 1 uraditi u bilo kom ciklusu tog bazičnog bloka.

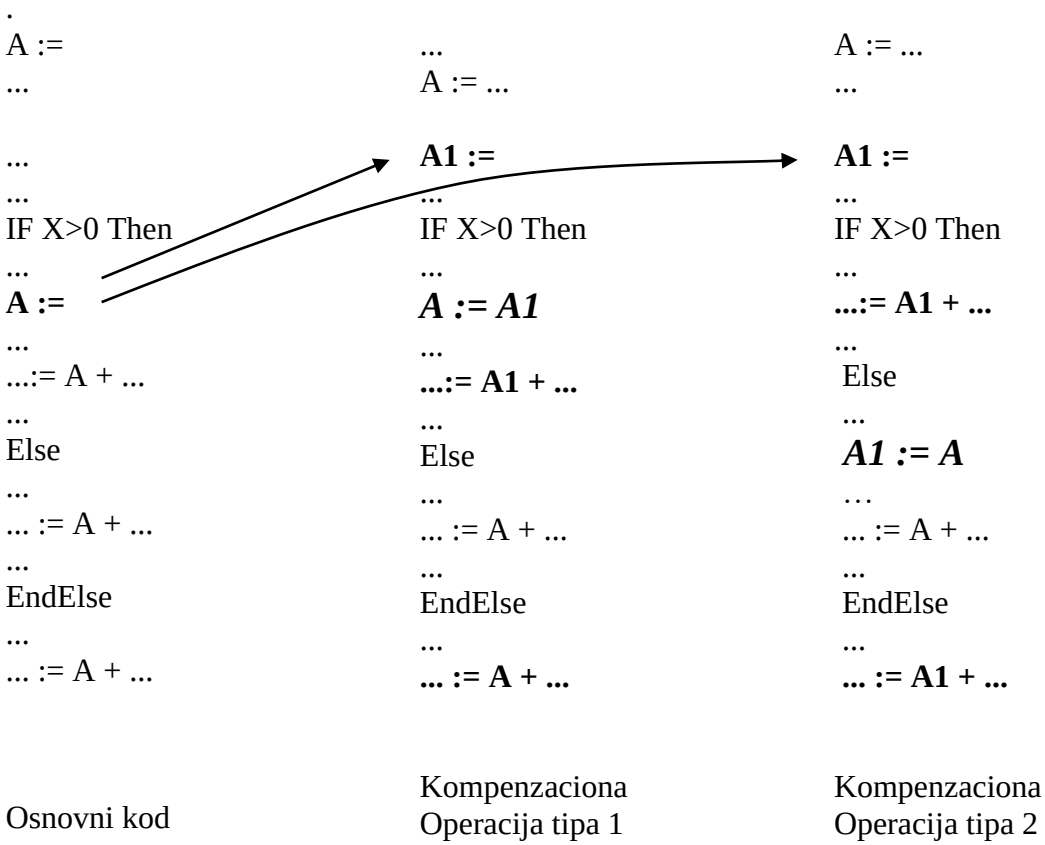


Sl. 4.1. Preimenovanja prilikom spekulativnog izvršavanja po kontroli

*Napomene uz Sl. 4.1.:*
Strelice označavaju spekulativnu selidbu sa neophodnim preimenovanjem.
Iste vrste označavaju ekvivalentne operacije, izuzev kada je razmak poremećen kompenzacionim operacijama naglašenim *italic slovima.*
Operacija + i ispitivanje uslova >0 su samo primeri operacija i uslova, čime se ne umanjuje generalnost pokazanih transformacija.

Na dovoljno paralelnom hardveru ovakva operacija ne može da dovede do produžavanja izvršenja programskog kôda. Izuzetak je samo slučaj kada se prilikom optimizacije kôda dogodi da se sve operacije eliminišu iz grane - bazičnog bloka, osim kompenzacione operacije tipa 1. Tada se kompenzaciona operacija može prebaciti u drugu granu, tako da se u njoj radi izjednačavanje preimenovane i nepreimenovane vrednosti. Tada se preimenuje ceo kôd iza uslovnih grananja i spojeva, izuzev dela kôda iz grane iz koje nije seljena operacija u kome se koristi stara vrednost promenljive. Ovo se naziva **kompenzaciona operacija tipa 2**. Ukoliko ima upisa u promenljivu u grani iz koje nije seljena operacija, tada se upis može definisati kao upis u preimenovanu promenljivu i kompenzaciona operacija tipa 2 nije neophodna.

Kompenzaciona operacija tipa 2 je takođe slobodna i na vrhu i na dnu bazičnog bloka. Ova tvrdnja proizilazi iz sledećih stavova:

a. Kompenzaciona operacija je potrebna samo ako u grani iz koje nije spekulativno pomerana operacija nema upisa u promenljivu za koju bi moralo da se radi preimenovanje.
b. Sve operacije u grani koje čitaju vrednost promenljive čitaju staru vrednost do eventualnog ponovnog upisa.

Izborom kompenzacione operacije tipa 1 ili tipa 2, uvek se može postići da spekulativno izvršavanje sa kompenzacionom operacijom ne dovede do produžavanja trajanja izvršenja programa, ako postoji dovoljan paralelizam u mašini. Zanimljivo je da jednom preseljena operacija preko jednog uslovnog grananja na gore, kod koje je moralo da se uradi preimenovanje, može da se dalje seli na gore preko proizvoljnog broja uslovnih grananja. To je moguće jer je njen rezultat sigurno mrtav u svim drugim granama uslovnih grananja preko kojih je preseljena na gore. Tako se jednim preimenovanjem dozvoljava da se operacija preseli preko proizvoljnog broja uslovnih grananja na gore.

Ako se posmatra ukupan efekat spekulativne selidbe operacije preko uslovnih grananja na gore i nabroje zaključci prethodnog razmatranja, sledi:

a. **Operacija se uvek može preseliti preko uslovnih grananja na gore ako ne generiše izuzetak**, bez obzira na to da li je njen rezultat živ u drugoj grani
b. Ako je rezultat živ u drugoj grani, mora se raditi preimenovanje.
c. Ukoliko na bilo kom tragu može da dođe do ponovnog spajanja tragova nakon uslovnih grananja i spojeva, može biti potrebna kompenzaciona operacija kojom se stapaju preimenovana i originalna promenljiva.
d. Kompenzaciona operacija nije neophodna ako se pre spajanja tragova javljaju upisi. Ako se upis javlja u grani iz koje je preseljena operacija, onda se upis obavlja u originalnu promenljivu, kao što je to bilo u originalnom kodu. Kada postoje dve grane, tada se stapanje originalne i preimenovane promenljive izvodi preko operacije upisa u jednoj od grana. Upis u grani iz koje nije preseljena operacija na gore se tada mora promeniti tako da bude upis u preimenovanu promenljivu i sve kasnije reference (čitanja) moraju takođe da se preimenuju. Naravno, upisi ne moraju da budu odmah u granama iza grananja, a ovde je naveden samo najjednostavniji slučaj.
e. Izborom grane u kojoj se nalazi kompenzaciona operacija, odnosno tipa kompenzacione operacije, može se postići da se **na dovoljno paralelnoj mašini**

**nikada ne produžava trajanje izvršavanja po bilo kom tragu, zbog postojanja kompenzacionih operacija**.

Kako u današnjim mašinama tipično postoji dovoljno paralelizma, spekulativna selidba operacija preko uslovnih grananja na gore predstavlja veoma privlačnu transformaciju, ravnopravnu sa bazičnim transformacijama selidbe operacija{PS 91}{SM 92}. Osnovna podrška za agresivnu primenu ove vrste spekulativnog izvršavanja je broj registara koji se koriste za preimenovanja. Osim toga, neophodno je da postoji dovoljno paralelizma za jednostavne kompenzacione operacije kojima se radi stapanje promenljivih preko prepisivanja sadržaja registara. Kompenzacione operacije se najčešće svode na izbor argumenta iz odgovarajućeg registra, tako da je logika za kompenzacione operacije u stvari selekciona logika za izbor registra sa odgovarajućim argumentom.

#### 4.4.1.2. Najbrže izvršavanje po svim tragovima

Pretpostavimo kôd bez programskih petlji. Kao ekstremum veoma agresivne primene spekulativnih selidbi preko uslovnih grananja na gore, sve operacije mogu se preseliti do svog najranijeg trenutka izvršavanja određenog samo pravim zavisnostima po podacima. Pritom će se događati selidbe preko spojeva na gore i preko uslovnih grananja na gore. Prilikom svake selidbe operacije preko spoja na gore, javljaju se dve kopije operacije. Istovremeno, i sva uslovna grananja bi se selila na gore do svog najranijeg mogućeg trenutka izvršavanja. Taj trenutak je određen najranijim trenutkom završetka operacije koja izračunava uslov za skok. Najranijim izvršavanjem grananja se smanjuje ukupan broj spekulativnih izvršavanja ostalih operacija. Na kraju bi se operacija (odnosno kopirane i spekulativne operacije proizašle iz te operacije) našle u bazičnom(im) bloku(ovima) u kome(jima) mogu da se izvršavaju u svom najranijem trenutku za sve tragove. Na taj način bi se, za dovoljno paralelnu mašinu, postiglo optimalno vreme izvršavanja za sve dinamičke tragove.

Eksplozija kôda pri ovakvim transformacijama je veoma velika, ali uzimajući u obzir veličinu memorija današnjih računara i razvoj tehnologije, može se u budućnosti očekivati primena ovako agresivne optimizacije kôda. U specijalnim slučajevima se ovako agresivna optimizacija može raditi (npr. za kôd unutrašnje petlje kod ugnježdenih petlji, kada postoje grananja). Ovakvom agresivnom optimizacijom pokazano je da se, zasada, spekulativnom selidbom preko grananja na gore postiže eliminacija kontrolnih zavisnosti i samim tim se kontrolne zavisnosti postaju manje značajan faktor u paralelizaciji kôda na instrukcijskom nivou.

#### 4.4.1.3. Detaljan primer dobijanja optimalnog kôda po svim tragovima.

Prikaz eliminacije kontrolne zavisnosti kod grananja u programskom kôdu otežan je činjenicom da se vrlo lako generiše veliki broj tragova izvršavanja. Najjednostavniji primer je IF-THEN-ELSE struktura sa po jednim bazičnim blokom pre grananja i posle spoja. Jedan primer za takav kôd u višem programskom jeziku predstavljen je na Sl. 4.2.b.

REGISTRI ŽIVI NA VRHU: X1, X2, X3, X4, X5, X6, X7, **Z6, Z7**, Z10, Z13

**MEĐUKOD:**

OP1: Yl := X3 * X4
OP2: Y2 := X5 - X6
OP3: T3 := X1 * X2
OP4: Y4:= T3 + 2
OP5: Y5 := X1 * X7

| **THEN** | **ELSE** |
|---|---|
| OP6: Z6 := X1-X3 | OP11: T11 : = Z7 + Y4 |
| OP7: Z7 := Z6 * Z6 | OP12: T12 := Z6 - T11 |
| OP8: T8 := Yl * Z7 | OP13: Z13 : = Y5 / T12 |
| OP9: T9 := Y2 + T8 | |
| OP10: Z10 := 7 * T9 | |

OP14: T14 := Z10 * Z13
OP15: Z15 := T3 - T14

a.

**VIŠI PROGRAMSKI JEZIK:**

```
Yl := X3 * X4;
Y2 := X5 - X6;
Y4 := X1 * X2 + 2;
Y5 := X1 * X7;
IF Y2>0 THEN DO (P=0,4)
   Z6 := XI - X3;
   Z7 := Z6 ** 2;
   Z10 := 7 * (Yl * Z7 + Y2); END
ELSE (P=0,6) Z13 := Y5 / (Z6 -
(Z7+Y4));
Z15 := X1* X2 - Z10 * Z13;
```

b.

REGISTRI ŽIVI NA DNU: Y5, **Z6, Z7**, Z10, Z13, Z15, ...

Sl. 4.2. Kôd IF-THEN-ELSE strukture i susednih bazičnih blokova.

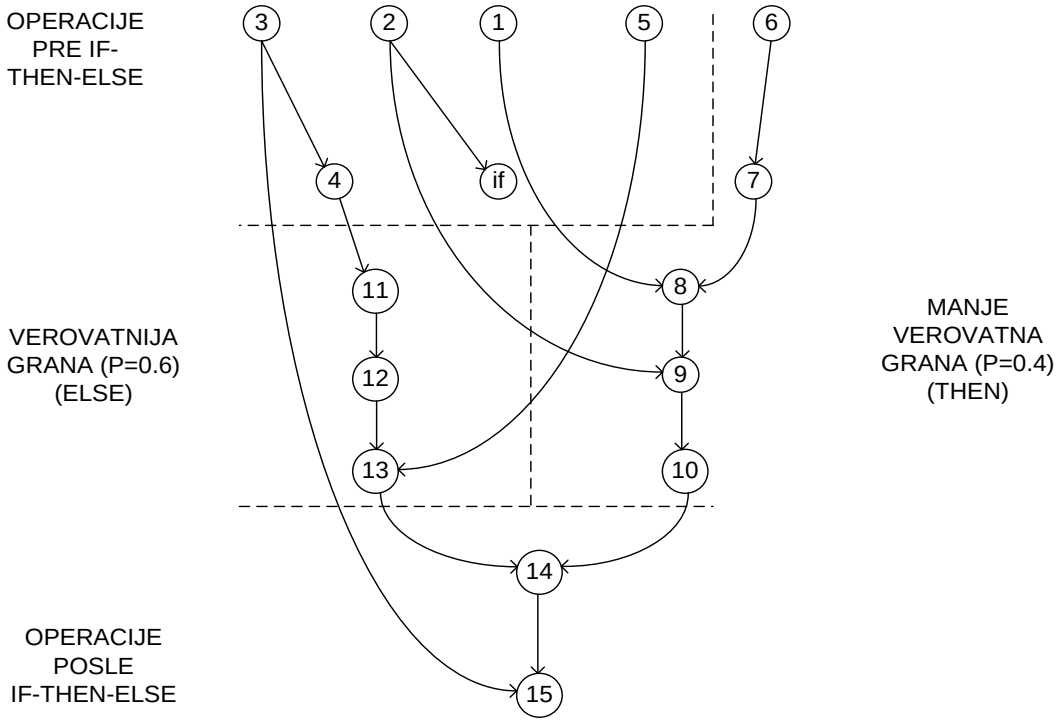


Sl 4.3. Graf zavisnosti po podacima za oba traga

Primenom elementarnih metoda optimizacije iz klasičnih prevodilaca, dobijen je međukod sa Sl. 4.2.a, pri čemu su registri za čuvanje međurezultata označeni sa Ti, a operacije sa OPi. Definisani su registri živi na vrhu i živi na dnu kôda, zbog ostatka programa koji nije prikazan u primeru. Uslov za skok na osnovu koje se određuje grana za izvršavanje dobija se na osnovu rezultata drugog reda kôda u obe predstave.

Na osnovu međukoda mogu se formirati grafovi zavisnosti po podacima za svaki od bazičnih blokova. Formiranjem takvih grafova maskirala bi se informacija potrebna za globalnu optimizaciju koda. Druga alternativa je da se formiraju aciklički grafovi zavisnosti po podacima za svaki od tragova (bazični blok pre grananja, kôd jedne od grana, bazični blok iza spoja). Da bi se lakše dočarao metod eliminacije uslovne antizavisnosti, grafovi zavisnosti po podacima oba moguća traga su integrisani, uz označavanje granica bazičnih blokova. Takva reprezentacija sa prikazom granica bazičnih blokova pomoću isprekidanih linija data je na Sl. 4.3. Ako svaka operacija traje po l ciklus, najkraće vreme izvršavanja traga sa *ELSE* granom (verovatniji trag) je 7 ciklusa na paralelnoj mašini, zbog postojećih zavisnosti po podacima.

Određivanje kritičnog puta drugog traga znatno je kompleksnije. Prvo je potrebno odrediti broj ciklusa potrebnih da se odredi test uslov na osnovu koje se vrši grananje. To vreme je dva ciklusa, jer je potrebno prvo odrediti rezultat OP2, a dodatni ciklus je neophodan da se ispita uslov za grananje, Preostali deo traga u THEN grani ima dužinu 7 ciklusa, tako da je ukupna dužina traga 9 ciklusa. Metodama selidbe operacija između bazičnih blokova koje ne koriste spekulativno izvršavanje, nije moguće preseliti OP6 pre uslovnog grananja, jer je promenljiva Z6 živa u drugoj grani.

Primer ponašanja klasičnih metoda optimizacije prikazan je za raspoređivanje po tragu (*Trace Scheduling*) na levoj koloni Sl. 4.4.a., po Trace Scheduling algoritmu bez spekulativnog izvršavanja. U primeru je ponovo korišćeno uprošćenje da sve operacije traju jedan ciklus.

Istovremena optimizacija oba traga može se sprovesti zahvaljujući metodi eliminacije kontrolnih zavisnosti preko preimenovanja uslovnih antizavisnosti. U prvom koraku utvrđuje se dužina segmenta kritičnog puta koji je ispred grananja za svaki od tragova. Dužina segmenta kritičnog puta traga ispred grananja za ELSE granu je 2, a za THEN granu 0, jer je pretpostavljeno da sve operacije traju 1 ciklus. Dužina kritičnog puta za određivanje uslova za grananje je 2 ciklusa, pa se delovi kôda koji moraju biti u granama mogu najranije javiti tek u trećem ciklusu. Segment kritičnog puta traga ELSE grane i kritičan put za izračunavanje test uslova imaju istu dužinu - ujedno i najveću dužinu među segmentima pre grananja. Deo kritičnog puta iz THEN grane dužine 2 ciklusa (operacije OP6 i OP7) mora se preseliti ispred grananja, pod pretpostavkom da ne mogu da generišu izuzetak, ako se želi najviši nivo paralelizma. To je moguće sprovesti samo eliminacijom uslovne antizavisnosti preimenovanjem i uvođenjem pomoćnih promenljivih Z6K i Z7K. U THEN grani se tada, ako se koristi kompenzaciona operacija 1, mora dodati kompenzacioni kôd kojim se dodeljuju vrednosti preimenovanih promenljivih originalnim promenljivama, ako se prolazi kroz tu granu. Kompenzacioni kôd se može izvršiti u bilo kom ciklusu u grani.

| RASPOREĐIVANJE PO TRAGU (PR. 1) | RASPOREĐIVANJE SPEKULATIVNA SELIDBA |
|---|---|
| 1, 2, 3 | |
| 4, 5 | |
| 6 11 | 2, 3, 6 |
| 7 12 | 1, 4, 7 |
| 8 13 | 5, 8, K6 11, 5 |
| 9 | 9, K7 12 |
| 10 | 10 13 |
| 14 | 14 |
| 15 | 15 |
| THEN 9 ELSE 7 | THEN 7 ELSE 7 |
| BROJ CIKLUSA POD PRETPOSTAVKOM DA SVE OPERACIJE TRAJU PO 1 CIKLUS | |

a. RASPOREDI OPERACIJA ZA LIW (Large Instruction Word) MAŠINU SA 3 PROCESORSKE JEDINICE

K6 i K7 su kompenzacione operacije tipa 1

VIŠI PROGRAMSKI JEZIK:

```
Yl := X3 * X4;

Y2 := X5 - X6;

Y4 := XI * X2 + 2;

Y5 := XI * X7;

Z6K := X1-X3;

Z7K := Z6K ** 2;

IF Y2>0 THEN DO (P=0,4)

   Z10 := 7 * (Yl * Z7K + Y2);

   Z6 := Z6K;

   Z7 := Z7K; END

ELSE (P=0,6)

   Z13 := Y5 / (Z6 - (Z7 + Y4));

Z15:= XI * X2 - Z10 * Z13;
```

b. KOD POSLE SELIDBI I SA DODATIM KOMPENZACIONIM OPERACIJAMA

Sl. 4.4. Rasporedi za raspoređivanje po tragu, eliminaciju uslovne antizavisnosti i kôd u višem jeziku posle eliminacije uslovne antizavisnost.

Konačni raspored operacija za VLIW mašinu sa 3 univerzalne aritmetičko-logičke jedinice dat je u desnoj koloni Sl. 4.4.a. Postignuto je da se kôd po oba traga izvršava za samo 7 ciklusa, primenom spekulativnog izvršavanja. Nijedna od osnovnih selidbi operacija nije mogla da ostvari ovaj rezultat za trag kroz THEN granu, jer je bilo neophodno eliminisati kontrolne zavisnosti, a to se moglo postići samo spekulativnim operacijama, uz dodatak kompenzacionih operacija. Konačni ekvivalentni kôd u višem programskom jeziku zajedno sa kompenzacionim kôdom dat je na Sl. 4.4.b.

### 4.1.1.4. Detaljan primer kada je potrebna kompenzaciona operacija tipa 2.

Neka je dat kôd u višem programskom jeziku koji predstavlja jednu IF-THEN-ELSE strukturu zajedno sa bazičnim blokovima pre grananja i posle spoja:

```
Registri živi na vrhu: X1, X2, X3, X4, X5, X6, X7, X8, Z6, Z7, Z9, Z10, Z11,...
Y1 := X5 + X6;
Y2 := X2 – X3;
Y3 := X1 * X4;
Y5 := (Y3 + X7) / 2;
IF Y2 > 0 THEN (P = 0,6)
        Z6 := Y5 ** 2;
        Z7 := Z6 – X5;
        Z9 := (Z7 + Y2) * X3;
END
ELSE (P = 0,4)
        Z10 := Y1 / X8;
        Z11 := 3 * Z10;
END
Y13 := (Z9 – Z11) * (Y3 + X7);

Registri živi na dnu: Y1, Y2, Y3, Y5, Y13, Z6, Z7, Z9, Z10, Z11,...
```

Sl. 4.5. Kod u višem programskom jeziku

U zagradama su naznačene verovatnoće izvršavanja THEN i ELSE grana određene na osnovu podataka koje je dao programer ili rada profilera. Klasični programski prevodilac dao bi sledeći međukod (Ti su pomoćni registri):

```
OP1: Y1 := X5 + X6
OP2: Y2 := X2 – X3
OP3: Y3 := X1 * X4
OP4: T4 := Y3 + X7
OP5: Y5 := T4 / 2
```

| THEN grana | ELSE grana |
|---|---|
| OP6: Z6 := Y5 * Y5<br>OP7: Z7 := Z6 – X5<br>OP8: T8 := Z7 + Y2<br>OP9: Z9 := T8 * X3 | OP10: Z10 := Y1 / X8<br>OP11: Z11 := 3 * Z10 |

```
OP12: T12 := Z9 – Z11
OP13: Y13 := T12 * T4
```

Sl. 4.6. Međukod

Uslov za grananje se izračunava u drugoj operaciji kôda tako da izvršavanje operacija u THEN ili ELSE grani zavisi od ishoda ove operacije. Ta situacija se može modelirati kontrolnom zavisnošću. Graf zavisnosti po podacima može se formirati za oba

dinamička traga koji postoje u ovom segmentu koda. Na slici 1. je prikazan objedinjeni graf zavisnosti po podacima koji uključuje oba traga.

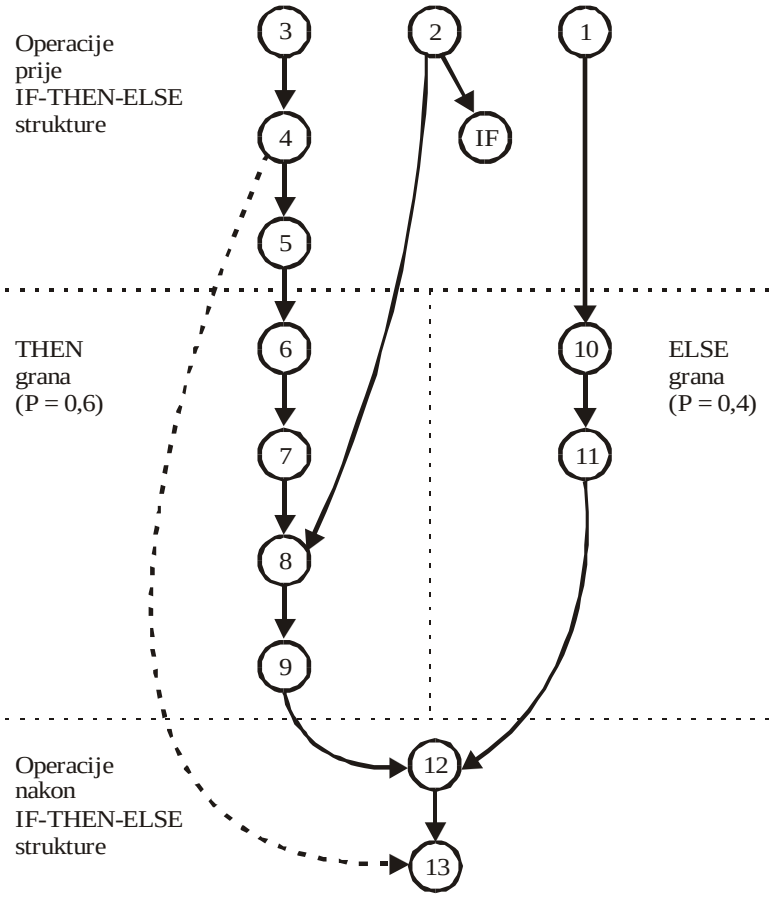


Slika 4.7. Objedinjeni graf zavisnosti po podacima za oba dinamička traga u međukodu. Isprekidanom linijom je prikazana tranzitivna zavisnost

Ukoliko pretpostavimo da trajanje svake od operacija iznosi jedan ciklus, onda je najkraće vreme izvršavanja dinamičkog puta koji uključuje verovatniju THEN granu 9 ciklusa. Na dinamičkom tragu koji sadrži ELSE granu, za određivanje i ispitivanje uslova grananja su takođe potrebna 2 ciklusa. Pošto operacija OP10 ne zavisi po podacima od operacije OP5, trajanje ostatka ovog dinamičkog traga iznosi 4 ciklusa, odnosno, minimalno trajanje celog dinamičkog traga, ukoliko se ne koristi spekulativno izvršavanje, iznosi 6 ciklusa. Ovo optimalno trajanje se može postići selidbom operacije OP5 preko grananja u obe grane na dole.

Dodatna optimizacija ovog segmenta kôda može se postići korišćenjem spekulativnog izvršavanja. Naime, operacije OP10 i OP11 iz ELSE grane ne zavise po podacima od operacija OP4 i OP5 te njihova selidba na gore preko grananja ima potencijal za ubrzavanje izvršavanja. Ovakva selidba rezultuje kodom u višem programskom jeziku u kojem je sada ELSE grana ostala prazna zbog čega se nameće potreba za korišćenjem kompenzacionih operacija tipa 2 {RI 05}.

```
Y1 := X5 + X6;
Y2 := X2 – X3;
Y3 := X1 * X4;
Y5 := (Y3 + X7) / 2;
Z10K := Y1 / X8;
Z11K := 3 * Z10K;
IF Y2 > 0 THEN
        Z6 := Y5 ** 2;
        Z7 := Z6 – X5;
        Z9 := (Z7 + Y2) * X3;
        Z10K := Z10;
        Z11K := Z11;
END
Y13 := (Z9 – Z11K) * (Y3 + X7);
```

Sl. 4.8. Kod u višem programskom jeziku sa kompenzacionom operacijom tipa 2

Da bi se sačuvala semantička ispravnost kôda i u ostatku programa ispod ovog segmenta neophodno je izvršiti preimenovanja promjenljivih Z10 i Z11 u Z10K i Z11K, respektivno.

Međukod ima sledeći oblik:

```
OP1: Y1 := X5 + X6
OP2: Y2 := X2 – X3
OP3: Y3 := X1 * X4
OP4: T4 := Y3 + X7
OP5: Y5 := T4 / 2
OP10: Z10K := Y1 / X8
OP11: Z11K := 3 * Z10K
```

| **THEN grana** |
|---|
| OP6: Z6 := Y5 * Y5<br>OP7: Z7 := Z6 – X5<br>OP8: T8 := Z7 + Y2<br>OP9: Z9 := T8 * X3<br>OP10K: Z10K := Z10<br>OP11K: Z11K := Z11 |

```
OP12: T12 := Z9 – Z11K
OP13: Y13 := T12 * T4
```

Sl. 4.9. Međukod sa kompenzacionom operacijom tipa 2

Primenom algoritma raspoređivanja po tragu i imajući u vidu da su kompenzacione operacije OP10K i OP11K slobodne i na vrhu i na dnu bazičnog bloka dobija se sledeći raspored:

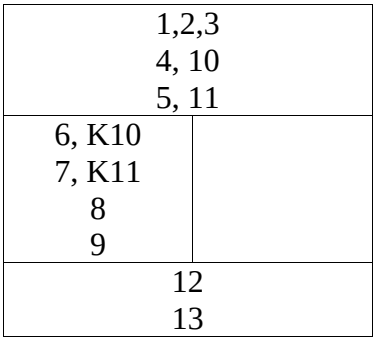


Sl. 4.10. Finalni raspored sa uklonjenom ELSE granom

Trajanje dinamičkog traga koji sadrži THEN granu ostalo je nepromenjeno, 9 ciklusa, dok je trajanje dinamičkog traga koji je u polaznom kodu sadržao ELSE granu, spekulativnim izvršavanjem operacija OP10 i OP11, smanjeno na 5 ciklusa. ELSE grana je naravno nestala, a to je i bio razlog za uvođenje kompenzacione operacije tipa 2.

## 4.4.2. Eliminacija kontrolnih zavisnosti u vreme izvođenja

### 4.4.2.1. Jedinstven tok kontrole (prediktori grananja)

Osnovni mehanizam sprovođenja spekulativnog izvršavanja po kontroli u cilju eliminacije kontrolnih zavisnosti u toku izvođenja je dinamička predikcija grananja. Neophodno je da mašina ima deo koji na osnovu istorije toka programa i eventualno nekih podataka iz vremena prevođenja obavi predikciju grananja. Tada se operacije predviđenog bazičnog bloka neposredno iza uslovnog grananja obavljaju spekulativno sve do trenutka u kome se odredi da li je predikcija grananja bila tačna ili ne. Ukoliko je predikcija grananja bila tačna i sve prethodne predikcije su bile tačne, operacije gube karakter spekulativnih i operacije koje su zavisile po podacima od tih operacija, bar po toj osnovi, ne moraju više da budu spekulativne. Naravno da se na osnovu ranijeg predviđenog skoka može raditi i predikcija narednog skoka, čime se efektivno u toku izvršavanja radi spekulativna selidba operacija na gore preko većeg broja grananja. Ove selidbe će biti detaljnije razmatrane u poglavlju o superskalarnim procesorima.

Osnovna ideja uvođenja dinamičkih prediktora je da se formira pretpostavljeni dinamički trag koji se ograničava po veličini i zato se često zove instrukcijski prozor. U tom dinamičkom tragu se može nalaziti nekoliko predviđenih skokova, tako da većina operacija kandidata za izvršavanje u tom instrukcijskom prozoru predstavljaju spekulativne operacije. Ubrzanje dobijeno ovakvim načinom eliminacije kontrolnih zavisnosti jako zavisi od kvaliteta prediktora grananja, jer pogrešna predikcija može da dovede do poništavanja rezultata velikog broja operacija i do potrebe da se briše sadržaj skoro kompletnog instrukcijskog prozora. Osnovni kvant spekulativnosti je u ovom slučaju bazični blok, jer se spekulativno u izvršavanje prebacuje najmanje ceo bazični blok, iako nije poznat ishod grananja. Zbog ogromnog značaja dobre predikcije grananja, samim prediktorima je posvećen deo 4.1.2.5. Današnji superskalarni procesori, koji dominiraju među najnovijim procesorima, upravo eliminišu kontrolne zavisnosti u vreme izvođenja primenom veoma kompleksnih prediktora grananja, pod uslovom da su pogođeni ishodi grananja. Ukoliko nisu, radi se oporavak i nakon toga opet pristupa predikciji grananja u cilju popunjavanja instrukcijskog prozora. Instrukcijski prozor je skup instrukcija koje čine ekvivalent virtuelnog dinamičkog bazičnog bloka koji se

menja sa svakim ciklusom, a on uključuje i instrukcije koje izračunavaju flagove za grananja, u cilju provere pretpostavljenog ishoda grananja.

Osnovna karakteristika ovog pristupa eliminacije kontrolnih zavisnosti je da se primenjuju vrlo agresivne metode optimizacije sa velikim instrukcijskim prozorima (danas oko 64 operacije, a orijentaciono oko 9 grananja!), a samim tim i tragovima. Ovde je namerno izbegnuta diskusija o tome kako se unutar tog prozora znaju zavisnosti po podacima i kako se dinamički trag unutar prozora paralelizuje. To se razmatra u poglavlju o superskalarnim procesorima.

#### 4.4.2.2. Više tokova kontrole (paralelni tragovi)

Ova kategorija podrazumeva da postoji istovremeno više jedinica za dohvatanje instrukcija, da se dohvatanje obavlja za različite procese i samim tim su različiti dinamički tragovi. Ako se uvede apstrakcija instrukcijskog prozora za deo dinamičkog traga, tada mora da postoji više instrukcijskih prozora, za sve predviđene različite dinamičke tragove procesa. Time se postiže da se delovi ukupnog kôda, koji su kontrolno nezavisni, istovremeno dohvataju ukoliko postoji paralelizam na nivou procesa. Na ovaj način se smanjuje potrebna dubina spekulativnosti za svaki pojedini trag, jer se koristi paralelizam procesa. Pogreške u predikciji unutar nezavisne niti na ovaj način ne utiču na ostale niti, pa se postiže efekat smanjenja prosečne štete nastale zbog pogrešne predikcije, zahvaljujući manjoj potrebnoj spekulativnosti. Naravno da bi se greške u predikciji propagirale u slučaju komunikacije niti. Zato se komunikacija niti obavlja tek kada je sigurno da komunikacija treba da se obavi i nijedan podatak u komunikaciji nije samo predviđen, već je i potvrđen.

Ovakve mašine moraju da imaju više prediktora grananja koji za nezavisne niti obavljaju simultanu predikciju grananja. Osim toga, mašina mora da podržava istovremene oporavke od istovremenih pogrešaka u predikciji grananja. U ovu kategoriju mašina spadaju multiskalarni i spekulativni višenitni (multithreaded) procesori. Takve osobine imaju mnogi najnoviji procesori, jer imaju podršku za istovremenu obradu više niti.

#### 4.4.2.3. Jedan tok kontrole sa hijerarhijskom sekvencom tragova

Generalizacija spekulativnog izvršavanja operacija je da se u paketu spekulativno izvršavaju tragovi. U ovom slučaju je neophodno da se kompletni tragovi izvršavaju na osnovu spekulativnih podataka i spekulativne kontrole. Hijerarhija sekvenci tragova se odigrava na sledeći način. Svaki trag je dat početnom adresom traga i sekvencom uslova kod grananja. Kraj traga je određen brojem instrukcija. Predikcija se radi na nivou N tragova, pri čemu su tragovi nanizani na osnovu predviđenih grananja u svim tragovima. Tragovi počinju da se rade na osnovu spekulativnosti i po podacima i po kontroli. Kada se izračunaju stvarne vrednosti kod spekulativnosti po podacima, radi se ponovno izračunavanje za operacije kod kojih je pogrešno predviđen podatak, ali ne i za operacije kod kojih je predikcija bila korektna. Na sličan način se postupa kada dođe do pogrešne predikcije kod kontrole. Zanimljiv je oporavak u ovom slučaju. Ako je pogrešna predikcija bila vezana za IF-THEN-ELSE strukturu, tada se oporavak radi samo za taj trag i nalazi se novo mesto spajanja tragova. Naravno da se i ovom prilikom čuvaju vrednosti svih operacija koje su bile i na ispravnom tragu, a ponovo se izračunavaju operacije do tačke spajanja sa spekulativno već izračunatim tragovima {RO 99}.

Ova izuzetno agresivna metoda spekulativnog izvršavanja je još u fazi ispitivanja na simuliranim mašinama. Još nije jasno da li će procesori sa ovako agresivnim metodama spekulativnog izvršavanja na nivou tragova biti široko primenjeni, jer je prosečan broj nepotrebnih operacija veliki.

#### 4.4.2.4. Dinamička predikcija grananja

Predikcija grananja se može obaviti statički i dinamički. Statička predikcija je već bila donekle objašnjena u poglavlju o Trace Scheduling-u, kada je opisivan postupak određivanja najverovatnijeg traga. Osnovna razlika između statičke i dinamičke predikcije grananja javlja se zbog načina na koji se definiše pretpostavljeni ishod grananja. Kod statičke predikcije, verovatniji ishod je određen u vreme prevođenja i ne može se menjati u toku izvođenja. Svaki dolazak do tog grananja u toku izvršavanja uvek dovodi do iste predikcije. Kod dinamičke predikcije, u toku izvršavanja se za isto grananje može menjati predviđeni ishod skoka. Samim tim dinamička predikcija ima velikih potencijalnih prednosti u odnosu na statičku. Informacija koja se može dobiti statički može da posluži za povećavanje verovatnoće pogotka dinamičkog prediktora. Takvi prediktori se često zovu hibridni prediktori grananja.

U predikciji grananja, neophodno je uraditi predikciju dve stvari, ishoda skoka i adrese skoka. Metode za predikciju adrese skoka su van interesa u ovoj knjizi, jer nisu striktno vezane za paralelizaciju kôda na instrukcijskom nivou. Pažnja je usredsređena na predikciju ishoda skoka, a kod nekih metoda će adresa skoka biti parametar koji se određuje paralelno sa procenom ishoda skoka.

Istorijski je zanimljivo da su postojala hardverska rešenja koja su predviđala ishod skoka na osnovu statičke predikcije. Ova jednostavna rešenja su pokazala relativno loše performanse, pa je početkom osamdesetih godina 20. veka započeto intenzivno istraživanje u oblasti dinamičkih prediktora.

Navedimo prvo ulazne podatke koji su u poznatim metodama korišćeni za predikciju grananja. Pre svega to mogu da budu podaci vezani za profiler ili dinamički prediktor koji su:

1. Statički određena verovatnoća grananja sa eventualnom procenom verodostojnosti te verovatnoće.
2. Verovatnoće pojavljivanja kombinacija prethodnih true i false vrednosti tog uslova grananja u nizovima određene dužine za sopstvenu istoriju grananja
3. Verovatnoće pojavljivanja kombinacija prethodnih true i false vrednosti okolnih uslova grananja u nizovima određene dužine za istoriju okolnih grananja
4. Zavisnosti prethodnih vrednosti od odredišnih adresa
5. Verovatnoće izvršavanja bazičnih blokova
6. Smer skoka (povratni skok ili skok unapred)
7. Vrste instrukcije uslovnog skoka (vrsta flag-a u procesorskoj statusnoj reči, …)

U ovom nabrajanju su navedeni samo osnovni ulazni podaci potrebni za predikciju grananja. U vreme profiling-a, može se ispitati ponašanje svakog grananja i naći optimalan prediktor za dinamičku predikciju grananja, za zadate ulazne skupove podataka. U tako opštem slučaju bi postojao širi skup prediktora grananja, od kojih bi se birao odgovarajući tip za svako od grananja. Kada je to jednom određeno tokom profiling-a, ulazna informacija za hibridni detektor treba da bude klasa prediktora koja

najviše odgovara nekom tipu grananja. Tako se mogu dobiti veoma kvalitetni dinamički prediktori, kod kojih je verovatnoće pogotka veoma visoka.

Svi ulazni parametri mogu da se koriste za statičku, a većina može da se koristi i za dinamičku predikciju, ali je razlika u tome što hardver mašine sa dinamičkim prediktorom mora da podrži dinamičko određivanje svakog od navedenih ulaznih podataka i mehanizam preslikavanja tih vrednosti preko tabela ili automata u predviđeni ishod grananja.

Kod dinamičke predikcije, prethodna istorija grananja mora da bude zapamćena na neki način u mašini i ažurirana nakon svakog grananja koje se odigra. Za pamćenje te istorije se koriste tabele i automati, a ulazni podaci su sledeći:

1. Kombinacija nizova true i false vrednosti u pomeračkim registrima određene dužine za sopstvenu (lokalnu) istoriju grananja – "sopstveni trag"
2. Kombinacija nizova true i false vrednosti u pomeračkim registrima određene dužine za globalnu istoriju svih prethodnih grananja na tragu – "korelacioni trag"
3. Adresa odredišta skoka (uključuje smer skoka)

Za različite kategorije grananja se mogu predvideti različiti prediktori po tipu i time ostvariti upareni prediktori. Pokazalo se da najuspešnije metode dinamičke predikcije grananja daju izuzetno visoke verovatnoće pogodaka. Neke od njih daju verovatnoće pogotka od preko 95%. To je i razlog što se u najnovijim procesorima može primeniti veoma agresivno spekulativno izvršavanje po kontroli.

### 4.4.2.5. Primeri dinamičkih prediktora

U daljem tekstu su predstavljena dva dinamička prediktora, od kojih je jedan opšteg tipa i predstavlja generalizaciju prediktora koji su predložili {YP 91}, a drugi je specifičan prediktor za grananja na kraju ugnježdenih programskih petlji.

**Tronivoski prediktor grananja**

Tronivoski prediktor grananja koristi tri nivoa ulaza za predikciju. Oni se nazivaju nivo korelacije, nivo istorije sopstvenog traga i automat koji pamti stanja istorije sopstvenog traga i radi predikciju. Informacija se na sva tri nivoa prikuplja dinamički i za to postoje odgovarajući registri i automati.

Nivo korelacije se prikuplja tako što se u pomerački registar zapamti korelacioni trag koji predstavlja snimak boolean vrednosti uslova za grananje za poslednjih K grananja na tragu. Na ovaj način se pamte ishodi svih K prethodnih grananja na dinamičkom tragu. Ova ulazna informacija je neophodna zato što je pokazano da ishod nekog grananja značajno zavisi od ishoda grananja koja su mu prethodila na dinamičkom tragu. Zbog postizanja agresivne spekulativnosti i pretpostavke da se postiže visoka verovatnoća pogotka, pomerački registar korelacionog traga popunjava se i predviđenim ishodima grananja, tako da predikcija može da napreduje nezavisno od stvarnih ishoda. Dubina ovog propagiranja je najčešće ograničena nekim malim prirodnim brojem (tipično je 4 – 10 spekulativno predviđenih grananja).

Drugi nivo je nazvan istorijom sopstvenog traga. Na tom nivou se pamti šta se događalo poslednjih p puta kao ishod izvršavanja te operacije grananja. Kako svako grananje ima svoju istoriju, neophodno je da postoji Tabela Registara Sopstvenog Traga (TRST).

Osnovna varijanta podrazumeva da se istorija skuplja posebno za svako grananje, a zbog isticanja pojedinačnog grananja to se naziva još i Per-Address istorija (svako grananje ima svoju adresu).

Zbog velikih hardverskih resursa potrebnih za predikciju, za ređe izvršavana grananja se radi objedinjavanje resursa. Jedna od takvih varijanti zasnovana je na ideji da se istorija vodi zajednički za skup grananja koji je definisan po nekom kriterijumu. Ovo rešenje se naziva Per-Set i omogućava da se objedinjavanjem koriste zajednički elementi nekih tipova grananja u generalnom prediktoru. Osim toga, moguće je da se kombinuje informacija za grananja koja su imala zajednički korelacioni trag prilikom pamćenja sopstvenog traga. Ovaj izlaz se dobije kao P bita iz tabele registara sopstvenog traga.

Izlazi prva dva nivoa služe za određivanje adrese kojom će se naći konačni automat koji preko svog stanja pamti istoriju sopstvenog traga. Dakle, to je automat koji preko svog stanja pamti **deo** istorije sopstvenog traga definisan sa prva dva nivoa i vrstom i stanjem automata. Prelazi stanja automata tog grananja se dakle obavljaju samo za određene vrednosti korelacionog i sopstvenog traga. Ovaj nivo vrši predikciju grananja i radi odmah i ažuriranje bita za korelacioni i sopstveni trag, pored prelaza stanja automata. Treći nivo je u osnovi tabela automata koji se selektuju na bazi informacija sa prva dva nivoa. Izabrani automat na osnovu svog stanja radi predikciju.

Generalni tronivoski model podrazumeva da svaki naredni nivo koristi izlaze prethodnih nivoa za izbor odgovarajućih polja ili automata. Ako se ukinu veze između nivoa kojima se smanjuje dubina veza, dobijaju se dvonivoske šeme koje su svojom implementacijom u Pentium-Pro procesoru dovele do revolucije u kompleksnosti prediktora grananja. Dvonivoske šeme su manje kompleksne i prilagođene su današnjem nivou tehnološkog razvoja.

Moguće je još i da postoje različiti tipovi automata. Preslikavanje skupa instrukcija uslovnog grananja na tip automata se određuje na osnovu trenutne adrese instrukcije u operativnoj memoriji, operacionog kôda naredbe i klase grananja koju određuje kompajler (a može da bude i rezultat profiling-a). Generalni prediktor je prikazan na Slici 4.11.

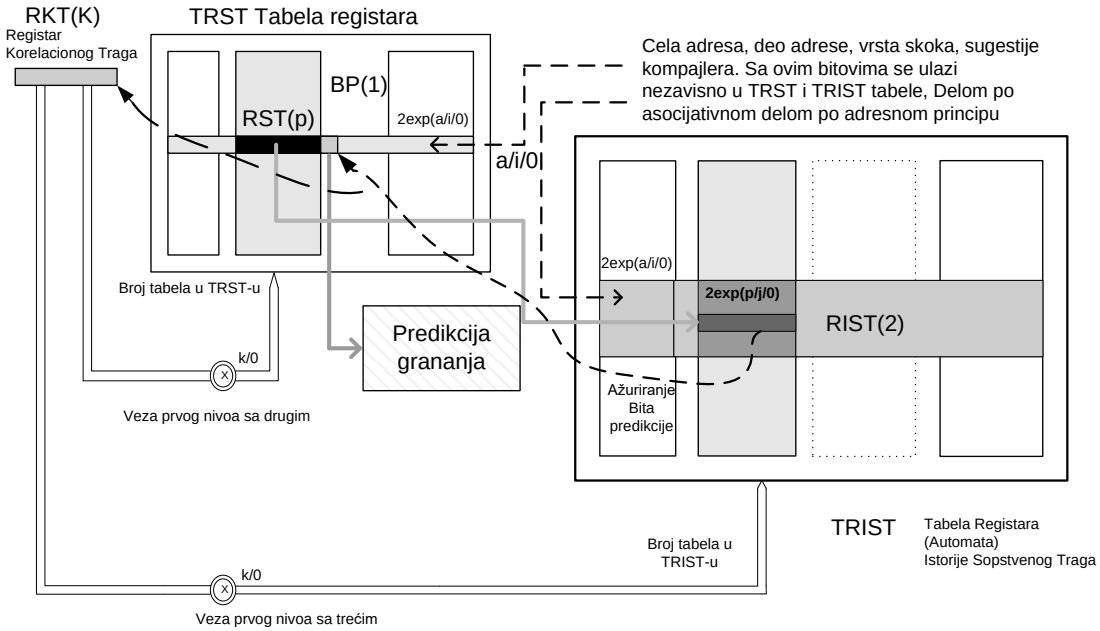


Slika 4.11. Opšta šema tronivovskog dinamičkog prediktora

Prvi nivo prediktora je obeležen sa RKT (Registar Korelacionog Traga), jer se odnosi na pomerački registar koji pamti ishode okolnih (prethodnih) grananja. Njegov naziv potiče od činjenice da postoji korelacija između ishoda susednih grananja na tragu i ishoda narednog grananja. Njegova dužina je k bita, a pokazalo se analizama na realnom kôdu da su vrednosti u opsegu od 4 do 14 bita dovoljne za dobru predikciju. Ovakav rezultat statistike mogao se i očekivati, jer samo relativno bliska ostala grananja na dinamičkom tragu mogu značajnije da utiču na neki skok.

Za sopstveni trag se koriste pomerački registri obeleženi sa RST (Registar Sopstvenog Traga) i dužine P bita. Broj ovih registara je veliki i u najopštijem slučaju, za svaki skok, je $2^{k+a}$, ukoliko postoji veza od prvog nivoa ka drugom i ukoliko se za posebne adrese pamti u nezavisnom registru sopstveni trag. Ni jedno ni drugo se tipično ne radi, jer bi prediktor bio suviše kompleksan. Tabela koja čuva vrednosti tih registara se naziva se Tabela Registara Sopstvenog Traga (TRST). Zbog veličine hardvera, retko se pravi veza prvog i drugog nivoa i retko se za različite adrese skoka koriste odvojeni registri sopstvenog traga. Svaki RST ima pridružen jedan ili više bita predikcije (BP) u koje se ubacuje(u) predviđena(e) vrednost(i) bita skoka. Prilikom potvrđivanja predikcije, BP se pomera u potvrđeni deo RST tog skoka. Ukoliko dođe do pogrešne predikcije, ubacuje se prava vrednost i poništava BP. Promene u prediktoru su male, ali usporavanje izvršavanja je ogromno, jer dolazi do poništavanja velikog broja spekulativnih operacija.

Osnovni element trećeg nivoa je registar istorije sopstvenog traga – RIST veličine N bita koji pamti stanje automata. U njemu se preko stanja automata pamti sopstvena istorija za neku vrednost korelacionog traga i to na način na koji to automat definiše. Ukupan broj ovih automata, ako se ne radi objedinjavanje za više grananja varira od $2^{k+p}$ do $2^{k+a+p}$.

Predikcija se obavlja svaki put kada se nakon dekodovanja naiđe na instrukciju uslovnog skoka. Tada je već stari sadržaj RKT mogao da odabere ulaz u TRST tabeli, ako postoji veza prvog i drugog nivoa. Vrednost RST (zajedno sa RKT) i eventualnim ostalim

delovima ulaza u TRST tabeli adresira Registar Istorije Sopstvenog Traga RIST (koji u osnovi sadrži stanje automata). Automat zatim radi predikciju grananja i rezultatom predikcije popunjava BP polja i same registre RKT i RST. Da bi prediktor obavljao posao za paralelizam današnjih procesora, neophodno je da u jednom ciklusu radi predikciju, ili da bar protočni niz prediktora svakog ciklusa izbaci novu prediktovanu vrednost bita skoka. Automati u raznim implementacijama imaju različite veličine memorije u bitima za pamćenje stanja (RIST), ali često vrednosti N koje su samo 2 (4 stanja) daju dobre rezultate.

Jedan od problema u implementaciji je da broj grananja prevazilazi broj lokacija memorije predviđenih za tabele prediktora i automate. Tada se primenjuje logika cache memorije ili preslikavanja više grananja na iste lokacije. Time se smanjuje tačnost prediktora, ali je to i neminovnost, jer prediktori grananja već imaju zavidan udeo u broju tranzistora današnjih najnovijih superskalarnih procesora. To i jeste razlog za uvođenje varijacija prediktora u kojima više različitih uslovnih grananja deli isti hardver u delovima vezanim za sopstvenu istoriju.

Spekulativna predikcija grananja može se raditi veoma daleko unapred, a ekstremum je doživela u trace procesorima {RO 99}{RS 99}. Danas je možda u prediktorima grananja najveći potencijal u daljoj paralelizaciji kôda na instrukcijskom nivou.

**Prediktor grananja ugnježdenih petlji**

Ideja ovog prediktora je da se izdvoje grananja za petlje od ostalih grananja i da se za njih realizuju odvojeni automati u okviru prediktora. Osnovni razlog za ovakvo odvajanje je činjenica da se za uslov iskakanja iz petlji, registar sopstvenog traga može pamtiti u specifičnoj komprimovanijoj formi. Tako se može sa istim brojem bita pamtiti mnogo duža istorija sopstvenog traga. Sama instrukcija uslovnog skoka petlje može se klasifikovati u vreme prevođenja, ali i u toku izvođenja, bilo na osnovu smera skoka ili kôda instrukcije.

Za nadgnježdene petlje se takođe može uspostaviti ista logika pamćenja duže istorije. Određivanje nadgnježdenosti se lakše može odrediti analizama u vreme prevođenja. Registar sopstvenog traga takvih uslovnih grananja sadrži niz brojača petlji koji broji broj iteracija petlje do izlaska iz nje.

Uvedena je pretpostavka o linearnoj zavisnosti broja iteracija unutrašnje petlje od trenutne vrednosti brojača nadgnježdenih petlji. Dakle, ukupan broj iteracija tekuće petlje je linearna kombinacija trenutnih vrednosti m brojača nadgnježdenih petlji. To se može prestaviti izrazom:
$i_0 = a_0 + a_1*i_1 + a_2*i_2 + a_3*i_3 + \ldots + a_m*i_m$
gde je $i_0$ ukupan broj iteracija tekuće ugnježdene petlje, $i_1$ trenutna vrednost broja završenih iteracija prve nadgnježdene petlje, a $i_m$ trenutna vrednost broja završenih iteracija m-te najbliže nadgnježdene petlje. Koeficijenti $a_i$ su celobrojni koeficijenti linearnosti koje u najkraćem intervalu učenja treba da odredi prediktor grananja, a da zatim sa najvećom verovatnoćom vrši predviđanje grananja. Naravno i u fazi učenja, prediktor treba najčešće da pogađa.

Učenje se izvodi na sledeći način: Pretpostavimo da su sve petlje normalizovane {AK87} u trenutku prevođenja. Tada se nakon $n_{11}$ iteracija dogodi da se iskoči iz petlje. Tako se odmah određuje da je $a_0 = n_{11}$. Nakon toga se obavi jedna iteracija nadređene petlje. Ako se sada nakon $n_{12}$ iteracija iskoči iz unutrašnje petlje, tada se dobija vrednost
$a_1 = n_{12} - a_0$.
Tako se iterativno na kraju dobijaju svi koeficijenti i ukoliko je ispunjena pretpostavka, dobija se dalje pogađanje sa verovatnoćom od 100 %. Hardver kojim se obavljaju ovakve predikcije opisan je u {ČE 95}.

Puštanjem velikog broja reprezentativnih programa, utvrđeno je da pretpostavka važi u velikom broju slučajeva ugnježdenih petlji, ali da bazični prediktor, čija je logika upravo opisana, puno greši kada pretpostavka nije ispunjena. Modifikacija prethodnog prediktora, u smislu uprošćavanja, dala je izuzetno dobre rezultate. Uprošćena pretpostavka proizašla iz skupa reprezentativnih tragova {MU 94}{KI 95} ukazivala je da broj iteracija u svakom narednom izvršavanju predstavlja prethodnu vrednost uvećanu za fiksan korak. Ovim se eliminišu sve zavisnosti predikcije od broja iteracija nadgnježdenih petlji. Pokazalo se da ovakav prediktor za sva grananja petlji na kojima je ispitan, daje izuzetno visoku prosečnu verovatnoću pogotka za uslovna grananja kod petlji od 97%. Detalji su opisani u {ČE 95}.