

LLVM

Ein Überblick




TECHNISCHE
UNIVERSITÄT
DARMSTADT

Compiler II: Fortgeschrittene Themen
4. Juni 2013

Julian Oppermann

Eingebettete Systeme und Anwendungen, Technische Universität Darmstadt





- ▶ LLVM ist **kein** Compiler!
- ▶ Die LLVM-IR ist eine Zwischendarstellung, auf die man eine Vielzahl von Quellsprachen abbilden kann.
- ▶ “The LLVM Compiler Infrastructure Project” koordiniert die Entwicklung der IR und vieler weiterer Unterprojekte.
- ▶ Typischer Einsatz als Compiler:
`clang` liest Quelltext und *benutzt* die LLVM-Bibliotheken zum Aufbau der IR, Optimierung und Codeerzeugung.




- LLVM Core** LLVM-IR, Analysen, Optimierungen, Codeerzeugung
- clang** C/C++/Objective-C Frontend
- dragonegg** Schnittstelle zu den Frontends der GCC
- LLDB** Debugger
- libc++** C++-Standardbibliothek
- compiler-rt** Laufzeitumgebung für Architekturen, denen bestimmte Instruktionen fehlen
- vmkit** LLVM-basierte virtuelle Maschinen für Java und .NET
- polly** Schleifentransformationen zur Verbesserung der Cachelokalität und zur automatischen Parallelisierung
- ⋮

- ▶ LLVM stand ursprünglich für **Low Level Virtual Machine**.
 - ▶ Aktuell wird nur noch das Akronym verwendet, da das Projekt mittlerweile viel umfassender geworden ist.
- ▶ Begonnen Dezember 2000 von Chris Lattner und Vikram Adve an der University of Illinois.
- ▶ Heute ein erfolgreiches Open Source-Projekt unter BSD-kompatibler Lizenz.
- ▶ Gewinner des ACM Software System Award 2012.
- ▶ Bekannte Unterstützer aus der Industrie: Apple (LLVM ist Grundlage von Apples Entwicklungswerkzeugen), Google.
- ▶ Morgen (5.6.): Release von LLVM 3.3!




- ▶ LLVM-IR ist eigenständige Sprache, enthält alle Programminformationen.
- ▶ Ermöglicht echte Entkopplung von Frontend, Optimierungen und Codeerzeugung.
 - ▶ Im Gegensatz zu allen anderen Sprachimplementierungen zu Beginn der Entwicklung!



- ▶ LLVM-IR ist eigenständige Sprache, enthält alle Programminformationen.
- ▶ Ermöglicht echte Entkopplung von Frontend, Optimierungen und Codeerzeugung.
 - ▶ Im Gegensatz zu allen anderen Sprachimplementierungen zu Beginn der Entwicklung!

ideal:




praktisch:




- ▶ LLVM-IR ist eigenständige Sprache, enthält alle Programminformationen.
- ▶ Ermöglicht echte Entkopplung von Frontend, Optimierungen und Codeerzeugung.
 - ▶ Im Gegensatz zu allen anderen Sprachimplementierungen zu Beginn der Entwicklung!



ideal:



praktisch:



- ▶ Modulare Architektur, bestehend aus wiederverwendbaren Bibliotheken



LLVM-Projekt


Was macht LLVM besonders?

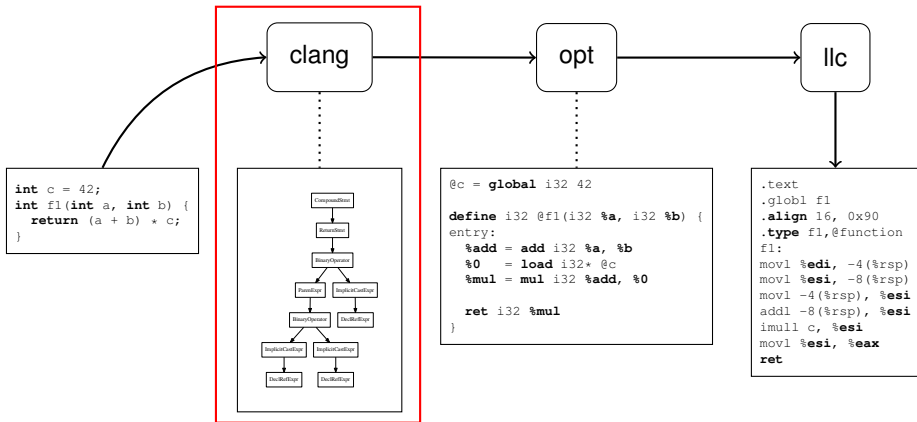


- ▶ clang
 - ▶ Schneller als gcc (compile time)
 - ▶ Bessere Fehlermeldungen

```
$ gcc-4.2 -fsyntax-only t.c
t.c:7: error: invalid operands to binary + (have 'int' and 'struct A')
$ clang -fsyntax-only t.c
t.c:7:39: error: invalid operands to binary expression ('int' and 'struct A')
    return y + func(y ? ((SomeA.X + 40) + SomeA) / 42 + SomeA.X : SomeA.X);
                        ~~~~~ ^ ~~~~~
```

- ▶ LLVM Core
 - ▶ Aggressive skalare Optimierungen
 - ▶ Link-time optimization
 - ▶ “easily hackable”





- ▶ Benutzt einen handgeschriebenen Parser nach dem Prinzip des rekursiven Abstiegs.
- ▶ Beispiel: if-Statement (stark vereinfacht)

```
StmtResult Parser::ParseIfStatement(SourceLocation *TrailingElseLoc) {
    SourceLocation IfLoc = ConsumeToken(); // eat the 'if'.

    if (Tok.isNot(tok::l_paren)) return StmtError();

    if (ParseParenExprOrCondition(CondExp, CondVar, IfLoc, true)) return StmtError();

    StmtResult ThenStmt (ParseStatement(&InnerStatementTrailingElseLoc));

    StmtResult ElseStmt;
    if (Tok.is(tok::kw_else))
        ElseStmt = ParseStatement();

    return Actions.ActOnIfStmt(...);
}
```

- ▶ Klassenhierarchien für Deklarationen (`Decl`), Anweisungen (`Stmt`) und Typen (`Type`).
 - ▶ Ausdrücke (`Expr`) sind Unterklassen von `Stmt`.
- ▶ Wurzelknoten ist `TranslationUnitDecl`.
- ▶ Keine gemeinsame Oberklasse, jeder Knotentyp spezifiziert seine eigenen Zugriffsmethoden:

```
class IfStmt : public Stmt {  
    ...  
    Expr *getCond() { return reinterpret_cast<Expr*>(SubExprs[COND]); }  
    Stmt *getThen() { return SubExprs[THEN]; }  
    Stmt *getElse() { return SubExprs[ELSE]; }  
    ...  
}
```

- ▶ Traversierung mittels `RecursiveASTVisitor` (“Makromonster”).

clang

AST (Beispiel)



```
int
```

```
addabs(int a,  
       int b)
```

```
{  
  int x;  
  if (a*b >= 0)  
    x = a+b;  
  else  
    x = a-b;  
  return x;  
}
```

```
TranslationUnitDecl 0x5ff6ba0 <<invalid sloc>>  
  '-FunctionDecl 0x5ff75d0 <../llvm-vortrag/cfg.c:1:1, line:8:1> addabs 'int (int, int)'  
    |-ParmVarDecl 0x5ff7490 <line:1:12, col:16> a 'int'  
    |-ParmVarDecl 0x5ff7500 <col:19, col:23> b 'int'  
    '-CompoundStmt 0x6023f10 <col:26, line:8:1>  
      |-DeclStmt 0x5ff76e8 <line:2:2, col:7>  
        |-VarDecl 0x5ff7690 <col:2, col:6> x 'int'  
        |-IfStmt 0x6023e80 <line:3:2, line:6:9>  
          | |-<<NULL>>>  
          | |-BinaryOperator 0x5ff77c8 <line:3:6, col:13> 'int' '>='  
          | | |-BinaryOperator 0x5ff7780 <col:6, col:8> 'int' '*'  
          | | | '-DeclRefExpr 0x5ff7700 <col:6> 'int' lvalue ParmVar 0x5ff7490 'a' 'int'  
          | | | '-DeclRefExpr 0x5ff7728 <col:8> 'int' lvalue ParmVar 0x5ff7500 'b' 'int'  
          | | '-IntegerLiteral 0x5ff77a8 <col:13> 'int' 0  
          | |-BinaryOperator 0x6023d60 <line:4:3, col:9> 'int' '='  
          | | |-DeclRefExpr 0x5ff77f0 <col:3> 'int' lvalue Var 0x5ff7690 'x' 'int'  
          | | '-BinaryOperator 0x5ff7898 <col:7, col:9> 'int' '+'  
          | | | '-DeclRefExpr 0x5ff7818 <col:7> 'int' lvalue ParmVar 0x5ff7490 'a' 'int'  
          | | '-DeclRefExpr 0x5ff7840 <col:9> 'int' lvalue ParmVar 0x5ff7500 'b' 'int'  
          | '-BinaryOperator 0x6023e58 <line:6:3, col:9> 'int' '='  
          | | |-DeclRefExpr 0x6023d88 <col:3> 'int' lvalue Var 0x5ff7690 'x' 'int'  
          | '-BinaryOperator 0x6023e30 <col:7, col:9> 'int' '-'  
          | | '-DeclRefExpr 0x6023db0 <col:7> 'int' lvalue ParmVar 0x5ff7490 'a' 'int'  
          | | '-DeclRefExpr 0x6023dd8 <col:9> 'int' lvalue ParmVar 0x5ff7500 'b' 'int'  
          '-ReturnStmt 0x6023ef0 <line:7:2, col:9>  
            '-DeclRefExpr 0x6023eb0 <col:9> 'int' lvalue Var 0x5ff7690 'x' 'int'
```



► (Gekürzte) LLVM-IR-Generierung für ein If-Statement


```
void CodeGenFunction::EmitIfStmt(const IfStmt &S) {
    llvm::BasicBlock *ThenBlock = createBasicBlock("if.then");
    llvm::BasicBlock *ContBlock = createBasicBlock("if.end");
    llvm::BasicBlock *ElseBlock = ContBlock;
    if (S.getElse())
        ElseBlock = createBasicBlock("if.else");
    EmitBranchOnBoolExpr(S.getCond(), ThenBlock, ElseBlock);

    EmitBlock(ThenBlock);
    EmitStmt(S.getThen());
    EmitBranch(ContBlock);

    if (const Stmt *Else = S.getElse()) {
        EmitBlock(ElseBlock);
        EmitStmt(Else);
        EmitBranch(ContBlock);
    }

    EmitBlock(ContBlock, true);
}
```

Übersicht



LLVM-IR

Ein Beispiel



TECHNISCHE
UNIVERSITÄT
DARMSTADT

```
int c = 42;  
int f1(int a, int b) { return (a + b) * c; }
```

LLVM-IR

Ein Beispiel



```
int c = 42;
int f1(int a, int b) { return (a + b) * c; }
```

```
@c = global i32 42
```

```
define i32 @f1(i32 %a, i32 %b) {
entry:
    %add = add i32 %a, %b
    %0   = load i32* @c
    %mul = mul i32 %add, %0

    ret i32 %mul
}
```

LLVM-IR

Ein Beispiel

```
int c = 42;
int f1(int a, int b) { return (a + b) * c; }
```

```
@c = global i32 42
```

Globale Variable

```
define i32 @f1(i32 %a, i32 %b) {
entry:
    %add = add i32 %a, %b
    %0   = load i32* @c
    %mul = mul i32 %add, %0

    ret i32 %mul
}
```

Funktionsdefinition

LLVM-IR

Ein Beispiel

```
int c = 42;  
int f1(int a, int b) { return (a + b) * c; }
```

```
@c = global i32 42
```

↑ ↑ ↑
Name Typ Initialer Wert

LLVM-IR

Ein Beispiel

```
int c = 42;
int f1(int a, int b) { return (a + b) * c; }
```

Rückgabebetyp Funktionsname Argumente

```
define i32 @f1(i32 %a, i32 %b) {
```

LLVM-IR

Ein Beispiel

```
int c = 42;
int f1(int a, int b) { return (a + b) * c; }
```

```
define i32 @f1(i32 %a, i32 %b) {
entry:
  %add = add i32 %a, %b ← Operanden
}
```

↑ Zielregister

↑ Opcode

↑ Ergebnistyp

LLVM-IR

Ein Beispiel



```
int c = 42;
int f1(int a, int b) { return (a + b) * c; }
```


```
@c = global i32 42
```

```
define i32 @f1(i32 %a, i32 %b) {
entry:
    %add = add i32 %a, %b
    %0   = load i32* @c
    %mul = mul i32 %add, %0

    ret i32 %mul
}
```



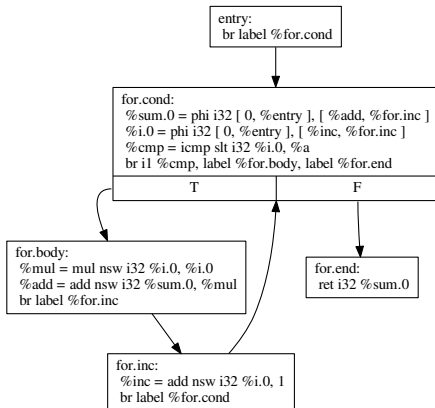
```
int addabs(int a, int b) {  
    int x;  
    if (a*b >= 0)  
        x = a+b;  
    else  
        x = a-b;  
    return x;  
}
```



CFG for 'addabs' function



```
int sumsqares(int a) {
    int sum = 0, i;
    for (i=0; i<a; i++) {
        sum += i*i;
    }
    return sum;
}
```



CFG for 'sumsqares' function



- ▶ Erkenntnis: Sieht aus wie eine Assembler-Darstellung für einen RISC-Prozessor.
 - ▶ unendlich viele Register
 - ▶ Jedes Register kann nur einmal von einer eindeutig bestimmten Instruktion beschrieben werden (→ **SSA-Form**).
 - ▶ typisiert
- ▶ “low level”: im Kontrast zu Java / .NET VMs
 - ▶ keine Klassen/Objekte
 - ▶ keine Vererbung
 - ▶ keine Polymorphie
 - ▶ kein Exception Handling
 - ▶ ...
 - ▶ **Aber:** alle diese Konstrukte lassen sich auf LLVM-IR abbilden!

- ▶ Steuerfluss: `ret` `br` `switch` `indirectbr` `invoke` `resume` `unreachable`
- ▶ Arithmetisch: `add` `fadd` `sub` `fsub` `mul` `fmul` `udiv` `sdiv` `fdiv` `urem`
`srem` `frem` `shl` `lshr` `ashr` `and` `or` `xor`
- ▶ Elementzugriff: `extractelement` `insertelement` `shufflevector` `extractvalue`
`insertvalue`
- ▶ Speicher und Adressierung: `alloca` `load` `store` `fence` `cmpxchg`
`atomicrmw` `getelementptr`
- ▶ Konversionen: `trunc` `zext` `sext` `fptrunc` `fpext` `fptoui` `fptosi` `uitofp`
`sitofp` `ptrtoint` `inttoptr` `bitcast`
- ▶ Andere: `icmp` `fcmp` `phi` `select` `call` `va_arg` `landingpad`



phi Die Φ -Funktion der SSA-Form

- ▶ explizite Instruktion, Tupel von Wert und Label als Argumente
- ▶ Beispiel:

```
%x = phi i32 [ %add, %then ], [ %sub, %else ]
```

call Funktionsaufruf

- ▶ abstrahiert Aufrufkonventionen, erhält Funktionsname und -argumente als Parameter
- ▶ Beispiel: **%y = call** i32 @Get_Bits(i32 1)

getelementptr Typsichere Adressrechnung


- ▶ Berechnet die Adresse von Array- oder Struktur-Elementen
- ▶ Beispiel: **int** arr[2]; arr[1] = ... →

```
%z = getelementptr [2 x i32]* %arr, i32 0, i32 1
```

Jeder Wert hat einen Typ (unabhängig von der Quellsprache)!

- ▶ Integerwerte: `i1`, `i8`, `i16`, `i32`, ...
alle Bitbreiten möglich, keine signed/unsigned-Unterscheidung
- ▶ Fließkommazahlen: `half`, `float`, `double`, ...
- ▶ Zeiger: `i64*`
- ▶ Arrays: `[10 x i32]`, `[2 x [2 x float]]`
- ▶ Strukturen: `{i32, float, i32}`
- ▶ Vektoren (SIMD): `<i8, i8, i8, i8>`
- ▶ ...

- ▶ Oberklasse für fast alle IR-Elemente: `Value` modelliert (SSA-)Werte.
 - ▶ Jeder Wert hat einen `Type`.
- ▶ (Vereinfachte) Klassenhierarchie:



- ▶ `Instructions` speichern ihre Operanden als Zeiger zu anderen `Value`-Objekten.
- ▶ **Beispiel: Konstruktor von `BranchInst`:**
`BranchInst(BasicBlock *IfTrue, BasicBlock *IfFalse, Value *Cond)`

- ▶ Toplevel-Konstrukt ist das `Module`: enthält Liste von `Functions`, globalen Variablen, ...
 - ▶ `getFunctionList()`, `getGlobalList()`, ...
- ▶ `Function` enthält Liste von `BasicBlocks`, organisiert als Steuerflussgraph.
 - ▶ `getEntryBlock()`, `getBasicBlockList()`, ...
 - ▶ Vorgänger-/Nachfolgerblöcke über spezielle Iteratoren `pred_iterator`, `succ_iterator`
- ▶ `BasicBlock` enthält Liste von `Instructions`.
 - ▶ `getTerminator()`, `getInstList()`, ...

API-Dokumentation: “`llvm::<Klassenname>`” googlen.



- ▶ Es gibt drei **äquivalente** Darstellungsformen:
 - ▶ textuell (Assembler-Format, siehe Beispiel) `prog.ll`
 - ▶ binär (Bitcode-Format) `prog.bc`
 - ▶ im Speicher (C++-Objekte)
- ▶ Jede Darstellungsform enthält stets alle Details des Programms
→ klare Schnittstelle für Analysen und Transformationen.
- ▶ Für alle Analysen und Transformation wird ausschließlich diese IR verwendet.

- ▶ LLVM-IR enthält genug Informationen, um auch “high-level” Analysen und Transformationen durchzuführen.
- ▶ Gekapselt als Pässe.
- ▶ Auszug aus der Liste der mitgelieferten Pässe:
 - ▶ Analysen: (Post-)Dominatorbaum, natürliche Schleifen, Aliasanalyse(n), ...
 - ▶ Transformationen: Dead Code Elimination, Reassociation, Loop Invariant Code Motion, Global Value Numbering, ...
- ▶ Abhängigkeiten zwischen Pässen werden automatisch aufgelöst.
- ▶ Man kann sogar Transformationen einzeln auf ein Programm anwenden:

```
$ opt -S -reassociate -o prog_opt.ll prog.ll  
$ opt -S -licm -o prog_opt2.ll prog_opt.ll
```

Optimierungen

Konstantenpropagation

```
while (!WorkList.empty()) {
    Instruction *I = *WorkList.begin(); WorkList.erase(WorkList.begin());


    if (Constant *C = ConstantFoldInstruction(I, TD, TLI)) {
        // Add all of the users of this instruction to the worklist, they might
        // be constant propagatable now...
        for (Value::use_iterator UI = I->use_begin(), UE = I->use_end(); UI != UE; ++UI)
            WorkList.insert(cast<Instruction>(*UI));

        // Replace all of the uses of a variable with uses of the constant.
        I->replaceAllUsesWith(C);

        // Remove the dead instruction.
        WorkList.erase(I);
        I->eraseFromParent();
    }
}
```

- ▶ Inhalt von `ConstantFoldInstruction`: “Erzeuge neue Konstante, wenn alle Operanden von `I` konstant sind”

Implementierung einer Peephole-Optimierung



(aus: Bersch, Thomas: Generierung lokaler Optimierungen. Diplomarbeit, 2012)



```
class SpecialSub : public FunctionPass {
    static char ID;
    SpecialSub() : FunctionPass(ID) {}

    bool runOnFunction(Function &F) {
        for (inst_iterator II = inst_begin(F), IE = inst_end(F);
            II != IE; ++II)
            performSpecialSubOptimization(&*II);
        return true;
    }
};

static RegisterPass<SpecialSub> X("specialsub",
    "Special_subtraction_transformation_pattern");
```



```
class SpecialSub : public FunctionPass { ←———— erben
```

```
    static char ID;
```

```
    SpecialSub() : FunctionPass(ID) {}
```

```
    bool runOnFunction(Function &F) {
```

```
        for (inst_iterator II = inst_begin(F), IE = inst_end(F);
```

```
            II != IE; ++II)
```

```
            performSpecialSubOptimization(&*II);
```

```
        return true;
```

```
    }
```

```
};
```

```
static RegisterPass<SpecialSub> X("specialsub",  
    "Special_subtraction_transformation_pattern");
```

Optimierungen

Pass-Implementierung



TECHNISCHE
UNIVERSITÄT
DARMSTADT

```
class SpecialSub : public FunctionPass { ←———— erben
    static char ID;
    SpecialSub() : FunctionPass(ID) {}
```

```
    bool runOnFunction(Function &F) { ←———— implementieren
        for (inst_iterator II = inst_begin(F), IE = inst_end(F);
            II != IE; ++II)
            performSpecialSubOptimization(&*II);
        return true;
    }
};
```

```
static RegisterPass<SpecialSub> X("specialsub",
    "Special_subtraction_transformation_pattern");
```

Optimierungen



Pass-Implementierung

```
class SpecialSub : public FunctionPass { ← erben
    static char ID;
    SpecialSub() : FunctionPass(ID) {}
```

```
    bool runOnFunction(Function &F) { ← implementieren
        for (inst_iterator II = inst_begin(F), IE = inst_end(F);
            II != IE; ++II)
            performSpecialSubOptimization(&*II);
        return true;
    }
};
```



```
static RegisterPass<SpecialSub> X("specialsub",
    "Special_subtraction_transformation_pattern"); ← registrieren
```

```
void performSpecialSubOptimization(Instruction *I) {  
    if (match(I, m_Sub(  
        m_Add(m_Value(X1), m_Value(X2)),  
        m_Add(m_Value(Y1), m_Value(Y2))  
    )) && X1 == X2 && Y1 == Y2) {  
  
        newSub = CreateSub(X1, Y1, "newsub");  
        newAdd = CreateAdd(newSub, newSub, "newadd");  
  
        newSub->insertBefore(I);  
        newAdd->insertBefore(I);  
  
        I->replaceAllUsesWith(newAdd);  
    }  
}
```




```
void performSpecialSubOptimization(Instruction *I) {  
    if (match(I, m_Sub(  
        m_Add(m_Value(X1), m_Value(X2)),  
        m_Add(m_Value(Y1), m_Value(Y2))  
    )) && X1 == X2 && Y1 == Y2) {  
        newSub = CreateSub(X1, Y1, "newsub");  
        newAdd = CreateAdd(newSub, newSub, "newadd");  
  
        newSub->insertBefore(I);  
        newAdd->insertBefore(I);  
  
        I->replaceAllUsesWith(newAdd);  
    }  
}
```



← Muster finden





```
void performSpecialSubOptimization(Instruction *I) {  
    if (match(I, m_Sub(  
        m_Add(m_Value(X1), m_Value(X2)),  
        m_Add(m_Value(Y1), m_Value(Y2))  
    )) && X1 == X2 && Y1 == Y2) {  
        newSub = CreateSub(X1, Y1, "newsub");  
        newAdd = CreateAdd(newSub, newSub, "newadd");  
        newSub->insertBefore(I);  
        newAdd->insertBefore(I);  
        I->replaceAllUsesWith(newAdd);  
    }  
}
```

← Muster finden

↑ erzeugen





```
void performSpecialSubOptimization(Instruction *I) {  
    if (match(I, m_Sub(  
        m_Add(m_Value(X1), m_Value(X2)),  
        m_Add(m_Value(Y1), m_Value(Y2))  
    )) && X1 == X2 && Y1 == Y2) { ← Muster finden  
  
        newSub = CreateSub(X1, Y1, "newsub");  
        newAdd = CreateAdd(newSub, newSub, "newadd");  
  
        newSub->insertBefore(I);  
        newAdd->insertBefore(I); ← erzeugen  
        ← einfügen  
  
        I->replaceAllUsesWith(newAdd);  
    }  
}
```



```
void performSpecialSubOptimization(Instruction *I) {  
    if (match(I, m_Sub(  
        m_Add(m_Value(X1), m_Value(X2)),  
        m_Add(m_Value(Y1), m_Value(Y2))  
    )) && X1 == X2 && Y1 == Y2) { ← Muster finden  
  
        newSub = CreateSub(X1, Y1, "newsub");  
        newAdd = CreateAdd(newSub, newSub, "newadd");  
  
        newSub->insertBefore(I);  
        newAdd->insertBefore(I); ← erzeugen  
  
        I->replaceAllUsesWith(newAdd); ← einfügen  
    }  
    }  
}
```

← Verwender anpassen



Optimierungen

Beispiel



```
int func(int a, int b) { return (a+a)-(b+b); }
```

Optimierungen

Beispiel



```
int func(int a, int b) { return (a+a)-(b+b); }
```

```
%add = add i32 %a, %a  
%add1 = add i32 %b, %b  
%sub = sub i32 %add, %add1  
ret i32 %sub
```

Optimierungen

Beispiel

```
int func(int a, int b) { return (a+a)-(b+b); }
```

```
%add = add i32 %a, %a  
%add1 = add i32 %b, %b  
%sub = sub i32 %add, %add1  
ret i32 %sub
```

```
↓ opt -load SpecialSub.so -specialsub -dce prog.ll ↓
```

Optimierungen

Beispiel



```
int func(int a, int b) { return (a+a)-(b+b); }
```

```
%add = add i32 %a, %a  
%add1 = add i32 %b, %b  
%sub = sub i32 %add, %add1  
ret i32 %sub
```

```
↓ opt -load SpecialSub.so -specialsub -dce prog.ll ↓
```

```
%newsub = sub i32 %a, %b  
%newadd = add i32 %newsub, %newsub  
ret i32 %newadd
```


Optimierungen können Analyseinformationen anfordern:

```
virtual void getAnalysisUsage(AnalysisUsage &AU) const {  
    AU.addRequired<AliasAnalysis>();  
}
```

Verwendung:

```
...  
AliasAnalysis &AA = getAnalysis<AliasAnalysis>();  
if (AA.alias(V1, V2)) {  
    ...  
}
```

- ▶ Einheitliche Schnittstelle für ...
 - ▶ Alias-Anfragen: $(Addr, Size) \times (Addr, Size) \rightarrow \{No, May, Must, Partial\}Alias$
 - ▶ ModRef-Anfragen: $(Instr, Addr, Size) \rightarrow \{No, Mod, Ref, ModRef\}$
 - ▶ `doesNotAccessMemory`, `onlyReadsMemory` für Funktionen
- ▶ Konvention: Analysen werden verkettet, deswegen auch sehr spezielle Verfahren möglich.
- ▶ Bequemere Verwendung der Information:
 - ▶ Memory Dependence-Analyse: findet Abhängigkeiten zwischen zustandsverändernden Instruktionen.
 - ▶ AliasSets: Einteilung von Zeigern in disjunkte Mengen.

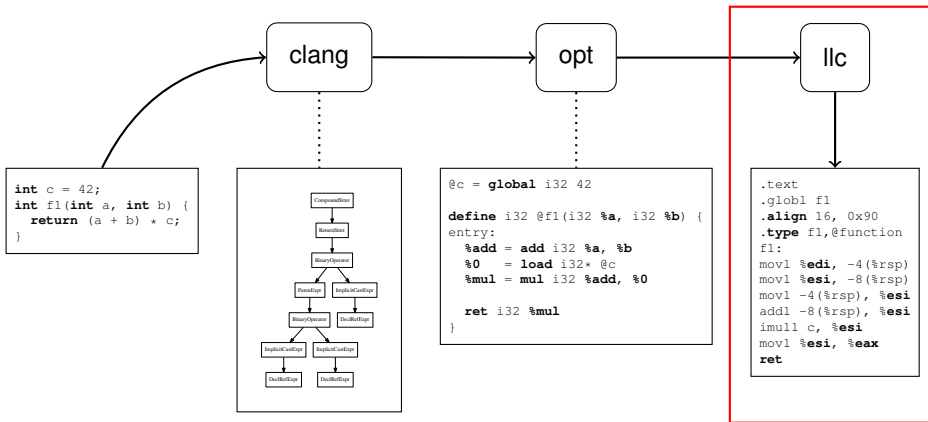
basic Analyse basierend auf Kenntnis von Fakten,
z.B. *“globale Variablen und allozierter Speicher auf Stack und Heap
aliasen nicht und sind nie `NULL`”*.

steens Steensgard Points-to-Analyse.

ds Data Structure Analysis (von den LLVM-Autoren).

scev Einbeziehung der Scalar-Evolution-Information, d.h. Entwicklung
von Werten in Schleifen.

globalsmodref Spezielle Analyse für globale Variablen, deren Adressen nicht
ausgewertet werden.



- ▶ Verfügbare Targets im Backend: x86, ARM, PowerPC, SPARC, MIPS, ...
- ▶ Abstrakte Beschreibung der Zielarchitektur: Befehlsformat, Registersatz, ...
 - ▶ Standardaufgaben der Codeerzeugung als architekturunabhängige Pässe verfügbar.
 - ▶ Instruktionsauswahl lässt sich größtenteils generieren.
 - ▶ Target-unabhängige JIT-Codeerzeugung

Mehr dazu beim nächsten Mal



- ▶ LLVM ist eine Sammlung von Bibliotheken und Werkzeugen zur Compilerentwicklung.
- ▶ LLVM-IR \approx Assembler für virtuelle Maschine mit typischen RISC-Befehlssatz plus ein paar Extras.
- ▶ Beim Design der Infrastruktur wurde größter Wert auf Modularität und Wiederverwendbarkeit der Komponenten gelegt.



- ▶ <http://llvm.org>
- ▶ <http://llvm.org/docs/LangRef.html>
- ▶ <http://llvm.org/docs/ProgrammersManual.html>
- ▶ <http://llvm.org/docs/WritingAnLLVMPass.html>
- ▶ <http://llvm.org/docs/WritingAnLLVMBackend.html>
- ▶ <http://llvm.org/docs/AliasAnalysis.html>
- ▶ <http://www.aosabook.org/en/llvm.html>
- ▶ Chris Lattner und Vikram Adve: "LLVM: A Compilation Framework for Lifelong Program Analysis & Transformation".



Backup-Folien



- ▶ C-Programm nach LLVM übersetzen:
\$ **clang** -S -emit-llvm -o prog.ll prog.c
- ▶ IR in “richtige” SSA-Form bringen:
\$ **opt** -S -mem2reg -o prog-ssa.ll prog.ll
- ▶ Zwischen Assembler- und Bitcode-Format konvertieren:
\$ **llvm-as** prog.ll # erzeugt prog.bc
\$ **llvm-dis** prog.bc # erzeugt prog.ll
- ▶ Codeerzeugung (= System-Assemblercode generieren)
\$ **llc** prog.ll # erzeugt prog.s



- ▶ Codequalität: kein klarer Sieger, leichter Vorteil für gcc 4.8 ggü. clang 3.2
- ▶ gcc unterstützt mehr Sprachen und Architekturen
- ▶ clang ist modularer, schneller und braucht weniger Speicher
- ▶ Linux Kernel: muss noch gepatcht werden, ARM besser unterstützt als x86.

http://www.phoronix.com/scan.php?page=article&item=llvm_clang32_final

<http://clang.llvm.org/comparison.html>

http://llvm.linuxfoundation.org/index.php/Main_Page