Einführung in den Compilerbau

Java Virtual Machine

TECHNISCHE UNIVERSITÄT DARMSTADT

Einführung in den Compilerbau
WS 2018/19

Andreas Koch

FG Eingebettete Systeme und ihre Anwendungen
Informatik, TU Darmstadt

Embedded Systems & Applications

Verbreitung von Java

TECHNISCHE UNIVERSITÄT DARMSTADT

- Java auf Platz 3 der populärsten Programmiersprachen [1]
- Jeder von Ihnen benutzt täglich Programme, die in Java geschrieben sind...
  - ...auf Ihrem Rechner
  - ...auf Ihrem mobilen Android-Device
  - ...in Ihrer Waschmaschine
  - ...in Einführung in den Compilerbau ;)

[1] spectrum.ieee.org/computing/software/the-2017-top-programming-languages

Verbreitung von Java

TECHNISCHE UNIVERSITÄT DARMSTADT

Java ist auf vielen verschiedenen Plattformen verfügbar:

- Desktop- und Server-Maschinen
- Mobile Endgeräte, insbesondere Android-Plattform
- Eingebettete Systeme, z.B.
  - Kaffeemaschinen
  - Waschmaschinen
  - Roboter
  - Fahrzeuge

Überall wo ein Java-Programm ausgeführt werden soll, muss die Java Plattform vorhanden sein

Java Plattform

TECHNISCHE UNIVERSITÄT DARMSTADT

Die sog. Java Plattform besteht aus 2 Hauptkomponenten

- Java API („Standardumgebung“)
  - Stellt Schnittstellen für grundlegende Funktionalitäten und Zugriff auf Ressourcen des Betriebssystems (Dateisystem, Netzwerk, etc.) bereit
- Java Virtual Machine (JVM)
  - Lädt vom Compiler erzeugte Klassen
  - Führt die geladenen Programme aus
  - Verwaltet und bereinigt den Speicher automatisch

Vorlesungsinhalt

TECHNISCHE UNIVERSITÄT DARMSTADT

- Wie ist die JVM intern aufgebaut?
- Wie funktioniert die Ausführung eines Programms auf der JVM?
- Wie kann im Compiler Code für die JVM erzeugt werden?
- Welche Vor- und Nachteile bietet eine virtuelle Ausführungseinheit wie die JVM?

Material und Referenzen

TECHNISCHE UNIVERSITÄT DARMSTADT

- Zwei etwas veraltete Lehrbücher
  - Meyer & Downing: *Java Virtual Machine*
  - Venners: *Inside the Java 2 Virtual Machine*

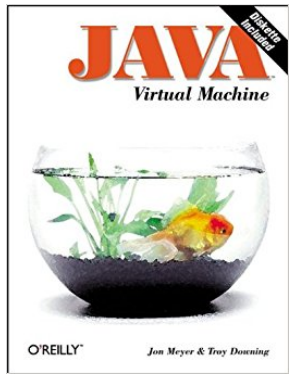

- Die offizielle Spezifikation:
  `https://docs.oracle.com/javase/specs/jvms/se9/jvms9.pdf`
- Eine Version des MAVL-Compilers mit Backend für die Java Virtual Machine im Moodle

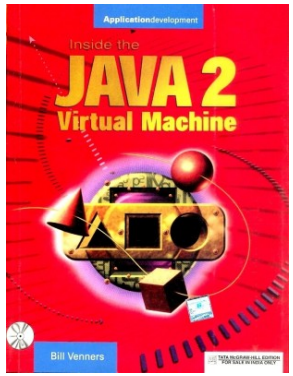

TECHNISCHE UNIVERSITÄT DARMSTADT

Java Virtual Machine

Java Virtual Machine

TECHNISCHE UNIVERSITÄT DARMSTADT

- Virtuelle Maschine: „Maschine auf der Maschine“
- Definiert eine Umgebung zur Ausführung von Bytecode unabhängig von zugrundeliegender Maschine
- Semantik und Funktionsweise der JVM durch Spezifikation vorgegeben[2]
- Verschiedene Implementierungen möglich, solange Spezifikation erfüllt wird
- Weitere Beispiele von JVM-Sprachen neben Java:
  - Scala
  - Groovy
  - Clojure
  - Kotlin

[2] https://docs.oracle.com/javase/specs/jvms/se9/html/index.html

Bytecode

TECHNISCHE UNIVERSITÄT DARMSTADT

- Programme, die in einer JVM-Sprache verfasst sind, werden zu Bytecode compiliert.
- Bytecode-Darstellung ist ein Mittelweg zwischen:

- Interpretierten Sprachen (z.B. JavaScript)
  - Programm wird in seiner Textform von einem Interpreter ausgeführt, häufig verbunden mit vorheriger Verifikation und dynamischer Typprüfung

- Maschinen-kompilierten Sprachen (z.B C/C++)
  - Programm wird von Compiler und Assembler in Maschinencode für die zugrundeliegende Maschine übersetzt

Vorteile der virtuellen Maschine

TECHNISCHE UNIVERSITÄT DARMSTADT

- Deutlich schneller als interpretierte Sprachen
- Interpreter muss vor Ausführung das Programm parsen, verifizieren und Typ-Checks durchführen
- Bei Bytecode ist Betrachtung der aktuellen Instruktion ausreichend, viele Überprüfungen bereits im Compiler durchgeführt.
- Wird noch verstärkt durch JIT-Kompilierung:
  - 10-20% des Codes machen bis zu 80-90% der Laufzeit aus $\rightarrow$ Übersetze häufig ausgeführten Code zur Laufzeit in nativen Maschinencode
- Vorteil gegenüber Maschinen-kompilierten Sprachen: Portabilität des Bytecodes

Portabilität - Nativer Maschinencode

TECHNISCHE UNIVERSITÄT DARMSTADT

- Erzeugter Maschinencode und kompilierte Bibliotheken sind an die jeweils zugrundliegende Maschine gebunden
- Portierung erfordert erneute Kompilierung
- Aufrufe zu Betriebssystem-funktionalitäten sind spezifisch für das jeweilige Betriebssystem und nicht portierbar

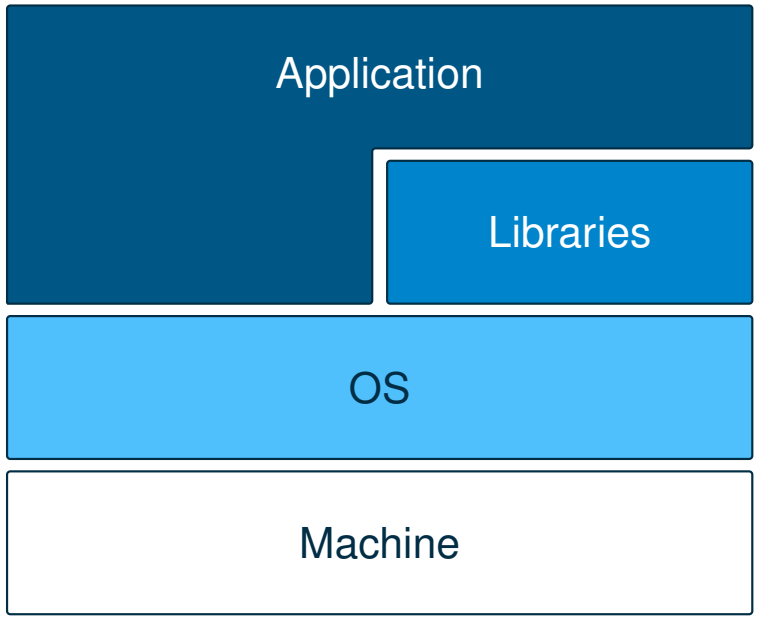

Portabilität - JVM Bytecode

TECHNISCHE UNIVERSITÄT DARMSTADT

- JVM abstrahiert über zugrundeliegende Maschine und Betriebssystem
- Anwendung und Bibliotheken nutzen betriebssystem-unabhängige API
- Bytecode wird von JVM interpretiert bzw. auf jeweilige Maschine abgebildet

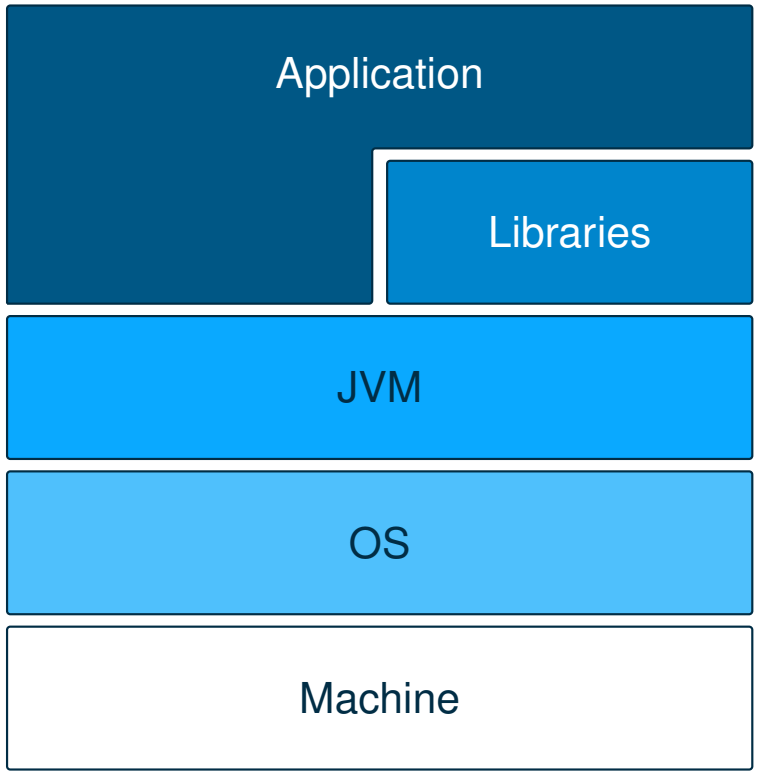

Portabilität - JVM Bytecode

TECHNISCHE UNIVERSITÄT DARMSTADT

- Bitbreiten sind auf allen Plattformen identisch (im Gegensatz zu z.B. C/C++)
- Anwendungen und Bibliotheken sind portabel zwischen verschiedenen Maschinen
- Zur Erschließung neuer Plattformen ist lediglich eine Portierung der JVM notwendig

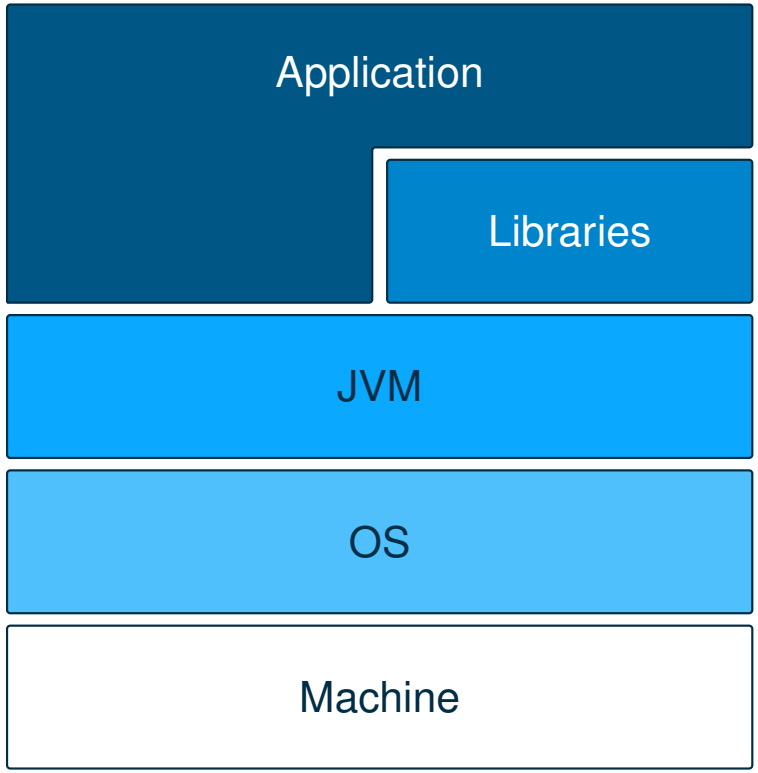

Portabilität - Bytecode mit *native* Methoden

TECHNISCHE UNIVERSITÄT DARMSTADT

- Sonderfall: Java-Code nutzt nativen Code (z.B. C/C++) über das *Java Native Interface (JNI)*
- Native-Code ist wieder maschinenspezifisch und muss explizit portiert und verfügbar gemacht werden

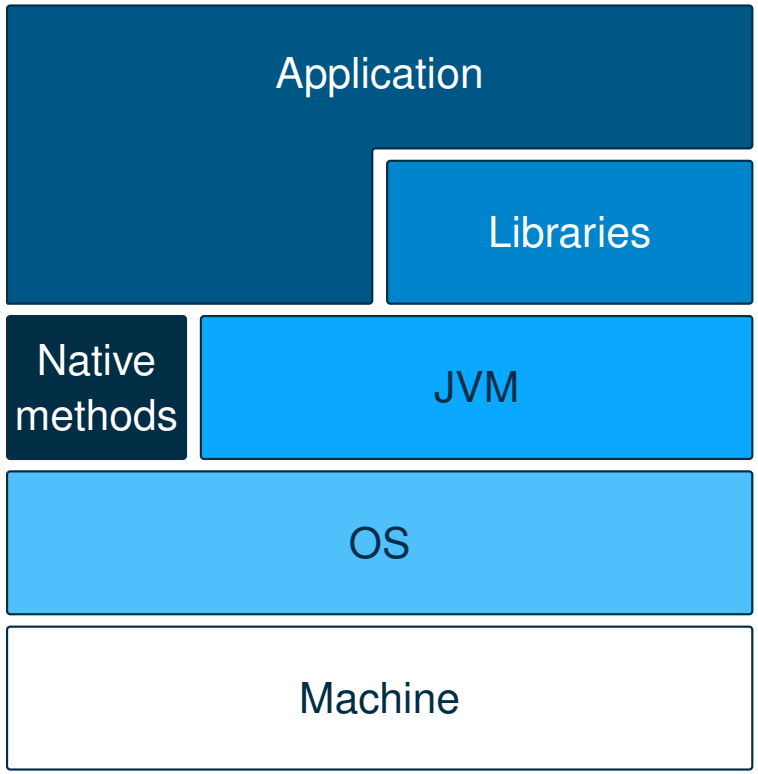

Vor- und Nachteile von virtuellen Maschinen

TECHNISCHE UNIVERSITÄT DARMSTADT

Weitere Vorteile von virtuellen Maschinen

- Implementierung von speziellen Operationen von unterstützten Sprachen möglich, z.B. `getfield, multinewarray`
- Alle Anwendungen profitieren von einmaliger Optimierung der virtuellen Maschine

Nachteile von virtuellen Maschinen

- Zusätzliches Abstraktionslevel kann Ineffizienzen verursachen. Mit JIT-Compilation ist die Performance von Java aber besser als ihr Ruf.
- Zur Ausführung von Anwendungen muss die virtuelle Maschine immer verfügbar sein.

Interner Aufbau der Java Virtual Machine

TECHNISCHE UNIVERSITÄT DARMSTADT

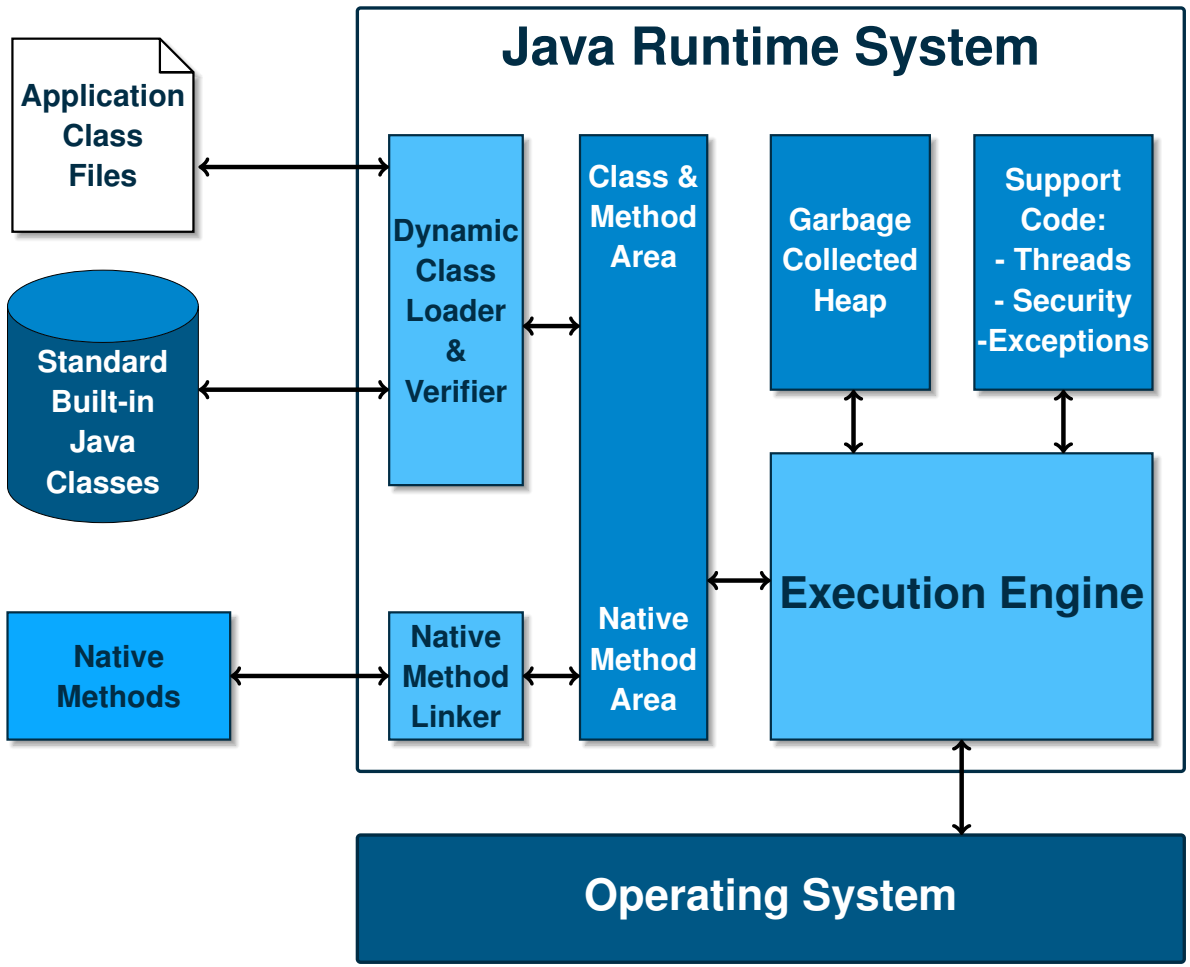

Komponenten der JVM

TECHNISCHE UNIVERSITÄT DARMSTADT

Memory Manager

- Objekte und Arrays werden auf dem *Heap* abgelegt und automatisch gelöscht, wenn sie nicht mehr benötigt werden
- Methoden- und Klassendefinitionen werden in separatem Bereich abgelegt und ebenfalls automatisch verwaltet

Error- und Exception-Manager

- Errors und Exceptions können sowohl von der Java-Runtime (z.B. Out-of-memory) als auch von Nutzercode geworfen werden
- Exception-Manager handhabt Exceptions
- Von Methode abgefangene Exceptions werden in *Handler Table* definiert

Komponenten der JVM

TECHNISCHE UNIVERSITÄT DARMSTADT

Native Method Support

- Native Method: Inhalt der Funktion in anderer Programmiersprache (z.B C/C++) verfasst und zu nativem Maschinencode compiliert
- Native Method Linker lädt Code aus Bibliothek (.dll/.so)
- Bei Aufruf einer Native Method müssen Argumente und Return-Wert umgewandelt werden (*Marshalling*)

Thread Management

- JVM unterstützt parallele Ausführung mit mehreren Threads
- Nur zwei Spezialanweisungen, Thread-Manangement hauptsächlich über Methoden von `java.lang.Thread`

JVM Class-File Format

TECHNISCHE UNIVERSITÄT DARMSTADT

Class File

- Ein Class File enthält alle von der JVM benötigten Informationen zu einer Klasse
- Von einem JVM-Compiler (z.B. `javac`) wird ein Class File pro Klasse erzeugt
  - Bei geschachtelten Klassen werden mehrere Files erstellt, so entstehen aus dem folgenden Code

```
public class Test{
    private class Inner{...}
}
```

    zwei Class Files: `Test.class` und `Test$Inner.class`
- Das Tool `javap` erlaubt die Untersuchung von Class Files

Class Files

TECHNISCHE UNIVERSITÄT DARMSTADT

Repräsentation

- Effiziente Darstellung und Speicherung in binärem, byte-basiertem Format
- Elemente größer als 8 Bit werden als Folge von Bytes in *big-endian*-Reihenfolge dargestellt

Class File-Struktur

TECHNISCHE UNIVERSITÄT DARMSTADT

Struktur

Interne Struktur besteht aus verschachelten Tabellen:

- *Top-level Table*: Generelle Informationen zur Klasse (Name, Eltern-Klasse, Zugriffsrechte)
- *Constant Pool Table*
- *Interface Tabelle*: Liste aller von dieser Klasse implementierten Interfaces
- *Fields Table*: Liste aller Felder der Klasse
- *Methods Table*: Liste aller Methoden
- *Attributes Table*: Aufzählung aller Attribute

Type Descriptor

TECHNISCHE UNIVERSITÄT DARMSTADT

Type Descriptors

JVM verwendet sogenannte *Type Descriptors* zur platzsparenden Speicherung von Typ-Informationen

Descriptor	Datentyp	Semantik
B	byte	Vorzeichenbehaftetes Byte
C	char	Character
D	double	Double-Precision IEEE-754 Gleitkommazahl
F	float	Single-Precision IEEE-754 Gleitkommazahl
I	int	Integer
J	long	Long Integer
S	short	Vorzeichenbehaftetes Short (16 Bit)
Z	boolean	true oder false

Type Descriptor

TECHNISCHE UNIVERSITÄT DARMSTADT

Klassentypen

- Zur Darstellung von Klassentypen wird ein String der Form „L<Klassenname>;“benutzt
- Im Package-Namen werden Punkte durch Schrägstriche ersetzt
- Beispiel: `java.lang.String` wird zu `Ljava/lang/String;`

Array-Typen

- Array-Typen werden mit einer Klammer gefolgt vom Element-Typen dargestellt:
  - `char[]` wird zu `[C`
  - `float[][]` wird zu `[[F`
  - `String[]` wird zu `[Ljava/lang/String;`

Type Descriptor

TECHNISCHE UNIVERSITÄT DARMSTADT

Methoden-Signaturen

- Zur Darstellung von Methoden-Signaturen wird ein String der Form „(<Argument-List>)<Return-Typ>“benutzt
- Beispielsweise wird `public int foo(char c, float f, String s)` zu `(CFLjava/lang/String;)I`
- Für Methoden mit Return-Typ `void` wird der spezielle Typdescriptor `V` verwendet, so wird `public void baz()` zu `()V`

Constant Pool

TECHNISCHE UNIVERSITÄT DARMSTADT

- Constant Pool enthält in seinen Einträgen eine ganze Reihe von Informationen:
  - Namen von Klassen, Methoden und Feldern
  - Konstante String-Literale
  - Konstanten der primitiven Typen `int`, `long`, `float` und `double`
- Zur Verwendung in Berechnungen bzw. in der Ausführung werden die Konstanten einfach mit ihrem Index referenziert
- Der Constant Pool spielt auch eine wichtige Rolle beim dynamischen Linken bzw. der dynamischen Auflösung von Referenzen zu anderen Klassen und deren Methoden

Constant Pool

TECHNISCHE UNIVERSITÄT DARMSTADT

Einträge im Constant Pool von `A` für Aufruf von `B.baz`:

1. String `"baz"`
2. String `"B"`
3. Type Descriptor `(I)V`
4. Klassen-Referenz für Klasse `B`, referenziert 2.
5. NameAndType für Methode `baz`, referenziert 1. und 3.
6. MethodenReferenz für `baz`, referenziert 4. und 5.

```
public class A{
  public static void foo(){
    B.baz("Hello, World!");
  }
}

public class B{
  public static void baz(int n){
    ...
  }
}
```

Constant Pool

TECHNISCHE UNIVERSITÄT DARMSTADT

```
[...]
#2 = Methodref          #13.#14         // B.baz:(I)V
[...]
#13 = Class              #17             // B
#14 = NameAndType        #18:#19         // baz:(I)V
[...]
#17 = Utf8               B
#18 = Utf8               baz
#19 = Utf8               (I)V
```

Class Loader

TECHNISCHE UNIVERSITÄT DARMSTADT

- Herzstück des dynamischen Linking in der JVM: Bei Aufruf von Methoden anderer Klassen wird der Class Loader zur Auflösung der Referenz verwendet
- Lokalisiert und lädt die Klassendefinition und macht sie in der JVM verfügbar
- Auflösen kann rekursive Aufrufe bedingen, z.B. Laden der Super-Klasse einer referenzierten Klasse
- Jede Klasse wird nur einmal aufgelöst, anschließend ist sie in der JVM verfügbar

Class Loader

TECHNISCHE UNIVERSITÄT DARMSTADT

Beim Laden einer Klasse für der Class Loader folgende Schritte aus:

1. Loading: Class File laden
2. Linking: Umwandlung des Class Files in JVM-interne Datenstrukturen (siehe Class- and Method-Area)
3. Verification: Überprüfung der Klassenstruktur und Sicherheitsprüfung durch den Security Manager
4. Preparation: Weitere Checks und Initialisierung der statischen Felder
5. Initialization: Aufruf der `<clinit>`-Methode nachdem alle Super-Klassen initialisiert wurden
6. Resolution: Auflösung von Einträgen im Constant Pool der gerade geladenen Klasse

Execution Engine

TECHNISCHE UNIVERSITÄT DARMSTADT

- Die Execution Engine ist das Herzstück der JVM
- „Virtueller Prozessor“, pro Thread eine Execution Engine. Virtuelle Prozessoren werden auf CPU-Kerne der Maschine abgebildet
- Heap-Speicher (Objekte und Arrays) und Methodenspeicher zwischen verschiedenen Instanzen geteilt
- Hauptaufgabe: Ausführung der Bytecode-Instruktionen
- Häufig ausgeführter Code wird zur schnelleren Ausführung per JIT-Compilation in Maschinencode umgewandelt

JVM Datentypen

TECHNISCHE UNIVERSITÄT DARMSTADT

Die Zahl der möglichen Opcodes in der JVM ist auf 256 limitiert (1 Byte). Daher gibt es nicht für jeden Java-Datentypen eine direkte Entsprehchung in der JVM:

- **`int`**, **`long`**, **`float`**, **`double`** sind die grundlegenden arithmetischen Typen auf der JVM
  - Für diese Typen sind die arithmetischen Operationen explizit definiert
  - Wörter auf der JVM sind grundsätzlich 32 Bit breit, **`long`** und **`double`** belegen daher stets 2 Worte
- **`short`**, **`char`**, **`byte`** sind sogenannte *storage types*
  - Können als Typen von Feldern und Arrays verwendet werden
  - Nur Speicheroperationen zur effizienten Speicherung der Elemente definiert
  - Zur Verwendung in Berechnungen erfolgt immer eine Umwandlung in **`int`**
- **`boolean`** werden als **`int`** mit Wert 0 oder 1 gehandhabt

JVM Datentypen

TECHNISCHE UNIVERSITÄT DARMSTADT

- Objekte und Arrays werden immer auf dem Heap ablegt, Elemente des Typs `reference` verweisen auf Instanz
- In Java werden Objekte und Arrays immer als Referenzen übergeben, kein „call-by-value“mit Objekten/Arrays
- Eine direkte Einbettung von Objekten in Objekten ist nicht möglich, immer nur per Referenz:

```
class Point{float x,y;};
class Line{Point p1, p2;};
```

- Keine Pointer-Arithmetik mit `reference` möglich

Stack Frames

TECHNISCHE UNIVERSITÄT DARMSTADT

Die Ausführung von Java-Programmen ist in Stack-Frames organisiert:

- Pro Thread/Execution Engine ein sogenannter *Java Stack*
- Bei Aufruf einer Methode wird ein neuer Stack-Frame auf dem Stack angelegt
- Nur der oberste Stack-Frame gilt als aktiv
- Beim Return wird der aktuellste Stack-Frame vom Stack entfernt
- Ein Stack-Frame erfasst den aktuellen Ausführungszustand in den folgenden Elementen
  - Register
  - Operand Stack
  - Local Variables

TECHNISCHE UNIVERSITÄT DARMSTADT

Register

- Keine allgemeinen Register, sondern Register für Zustandsvariablen
  - Stack-Top Index
  - Zustandsinformationen zum Thread
  - Pointer...
    - ...zur aktuellen Methode
    - ...zur aktuellen Klasse
    - ...dem Constant Pool der aktuellen Klasse
    - ...zum aktuellen Stack-Frame
  - Program Counter

- Keine Instruktionen zur direkten Manipulation der Register vorhanden

Operand Stack

- JVM ist eine stack-basierte Machine, alle Berechnungen werden auf dem Stack durchgeführt
- Elemente auf dem Stack sind 1 Wort (32 Bit) breit, **`double`** und **`long`** belegen 2 Elemente
- Operand Stacks sind pro Methode isoliert, kein Zugriff auf Stacks anderer Methoden

Local Variables

- Menge von nummerierten Local Variables
- Enthält:
  - `this`-Parameter (außer bei `static`-Methoden)
  - Parameter
  - Methoden-lokale Variablen
  - Häufig benutzte Werte/Berechnungen
- Implementierungen können Local Variables auf Hardwareregister der zugrundeliegenden Maschine abbilden

TECHNISCHE UNIVERSITÄT DARMSTADT

Exkurs: ASM-Framework

Code-Generierung

TECHNISCHE UNIVERSITÄT DARMSTADT

- Ergebnis der Code Generierung für die JVM ist eine binäre Byte-Datei
- Direkte Generierung dieser Datei möglich, aber kompliziert
- Neben den eigentlichen Instruktionen enthält Bytecode noch weitere Informationen, die hinzugefügt werden müssen, z.B.
  - Maximale Größe des Operandenstacks pro Funktion
  - Maximale Anzahl lokaler Variablen pro Funktion
  - *Stack Map Frames* zur schnelleren Verfikation

- Daher besser Verwendung eines Frameworks zur JVM Code Generierung

ASM Framework

TECHNISCHE UNIVERSITÄT DARMSTADT

- In dieser Vorlesung verwenden wir daher das ASM-Framework[3]
- Verfügbar unter Open-Source Lizenz
- Ermöglicht Analyse, Transformation und Generierung von JVM-Bytecode
- Sehr benutzerfreundlich und effizient
- Zwei verschiedene APIs verfügbar
  - Event-based API: Analyse/Generierung als Sequenz von Events
  - Tree-based API: Darstellung und Manipulation als Baum von Objekten
- Wir verwenden die Event-based API in unseren Beispielen

[3] **http://asm.ow2.org/**

Setup

TECHNISCHE UNIVERSITÄT DARMSTADT

Erzeuge leere, **public** Klasse mit Default-Konstruktor, die von `Object` erbt:

```
ClassWriter cw = new ClassWriter(ClassWriter.COMPUTE_MAXS);

cw.visit(Opcodes.V1_6, Opcodes.ACC_PUBLIC, className, null,
    "java/lang/Object", null);

Method m = Method.getMethod("void <init> ()");
currentGenerator = new GeneratorAdapter(ACC_PUBLIC, m, null,
    null, cw);
currentGenerator.loadThis();
currentGenerator.invokeConstructor(Type.getType(Object.class),
    m);
currentGenerator.returnValue();
currentGenerator.endMethod();
...
cw.visitEnd();
```

Setup

TECHNISCHE UNIVERSITÄT DARMSTADT

Erzeuge neue **`public static`** Funktion für MAVL-Funktion mit Namen `m`

```
GeneratorAdapter currentGenerator = new
    GeneratorAdapter(ACC_PUBLIC + ACC_STATIC, m, null, null,
    cw);

...

currentGenerator.endMethod();
```

TECHNISCHE UNIVERSITÄT DARMSTADT

Code-Generierung für die JVM

Typisierter Bytecode

TECHNISCHE UNIVERSITÄT DARMSTADT

- JVM Bytecode ist typsiert, d.h. es werden verschiedene Operationen für verschiedene Typen von Operanden verwendet
- Erlaubt z.B. Typprüfungen durch den Bytecode-Verifier
- Typ wird durch Präfix gekennzeichnet

Typ	Präfix	
int	i	
long	l	
float	f	
double	d	
byte	b	} Storage Types, nur für Load & Store
char	c	
short	s	
reference	a	} Verwendet für Objekte und Arrays

Datenoperationen

TECHNISCHE UNIVERSITÄT DARMSTADT

- Verwalten von Daten im Programm, umfasst Laden, Speichern und Verschieben von Daten
- Drei grundsätzliche Arten von Speicher
  - Operandenstack
  - Local Variables
  - Objekte und Arrays auf dem Heap
- Das Laden von Konstanten, auch aus dem Constant Pool, zählt ebenfalls zu den Aufgaben

Laden von Konstanten

TECHNISCHE UNIVERSITÄT DARMSTADT

- Allgemein: Laden von Konstanten aus dem Constant Pool mit **`ldc, ldc_w, ldc2_w`**
  - **`ldc`** lädt eine Single-Word Konstante aus den ersten 256 Einträgen
  - **`ldc_w`** verwendet breiteren Index und kann Single-Word Konstanten aus dem gesamten Pool laden
  - **`ldc2_w`** lädt Double-Word Konstanten (**`long, double`**)
- Spezialinstruktionen für arithmetische Konstanten, z.B.:
  - **`bipush/sibush`** für 1/2 Byte große, vorzeichenbehaftete Konstanten
  - **`iconst_m1`** für -1
  - **`iconst_<n>`** für Integer-Konstanten mit $0 \leq n \leq 5$
- Weitere Spezialinstruktionen für andere arithemtische Typen und **`null`**

Laden von Konstanten

TECHNISCHE UNIVERSITÄT DARMSTADT

- Das ASM-Framework trifft automatisch die Auswahl der passendsten Instruktion zum Laden einer Konstanten
- Folgender Code ist ausreichend für die Code Generierung von MAVL Integer Literalen:

```
@Override
public Instruction visitIntValue(IntValue intValue, Integer
    _)
{
        currentGenerator.push(intValue.getValue());
        return null;
}
```

Laden von Konstanten

TECHNISCHE UNIVERSITÄT DARMSTADT

Folgender Code wird dabei von ASM erzeugt:

- Für das Integer-Literal 1: **`iconst_1`**
- Für das Integer-Literal 42: **`bipush 42`**
- Für das Integer-Literal -1337:

```
sipush 1337
ineg
```

- Für das Integer-Literal 45123:

```
Constant Pool:
#17 = Integer 45123
...
ldc           #17
```

Verwaltung des Operandenstack

TECHNISCHE UNIVERSITÄT DARMSTADT

Verschiedene Operationen zur Manipulation von Elementen auf dem Operandenstack

- **pop**: Entferne das oberste Wort vom Stack
- **pop2**: Entferne die beiden obersten Worte vom Stack
- **dup**: Dupliziere das oberste Wort
- **dup2**: Dupliziere die obersten beiden Worte
- **swap**: Vertausche die obersten beiden Worte

Auf Double-Words (`long`, `double`) dürfen nur pop2 und dup2 angewendet werden!

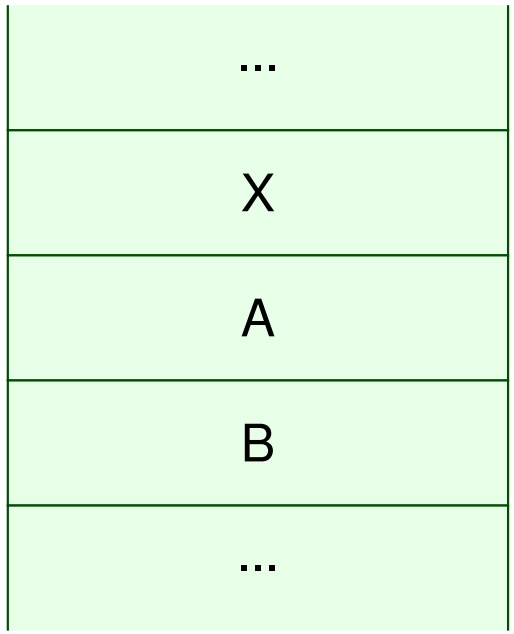

Arbeiten mit Local Variables

TECHNISCHE UNIVERSITÄT DARMSTADT

- Um die Daten in lokalen Variablen zu modifizieren, müssen diese immer zuerst auf/vom den Operandenstack geladen/gespeichert werden. Eine direkte Bearbeitung der lokalen Variablen ist nicht möglich
  - Einzige Ausnahme: **`iinc`** erlaubt das direkte Inkrementieren von Integer-Variablen

- Grundsätzlich zwei Operationen, wobei **`<p>`** eines der Präfixe **`i,l,d,f,a`** sein muss:
  - **`<p>load`** zum Laden von Werten auf den Stack
  - **`<p>store`** zum Speichern von Werten vom Stack|

- Lokale Variablen werden dabei per Index identifiziert

Arbeiten mit Local Variables

TECHNISCHE UNIVERSITÄT DARMSTADT

Das ASM-Framework stellt einfache Methoden bereit, um Code für den Zugriff auf lokale Variablen zu generieren:

- Anlegen einer neuen lokalen Variable vom Typ `type`:

```
int offset = currentGenerator.newLocal(type);
```

- Laden eines primitiven Funktionsarguments `arg`:

```
currentGenerator.loadArg(arg);
```

- Laden einer lokalen Variablen mit Typ `type` an Index `offset`:

```
currentGenerator.loadLocal(offset, type);
```

- Speichern in eine primitive lokale Variable mit Typ `type` an Index `offset`:

```
currentGenerator.storeLocal(offset, type);
```

Zugriff auf Local Variables

TECHNISCHE UNIVERSITÄT DARMSTADT

Aus dem folgenden MAVL-Code

```
function void foo(int a){
  val int b = 5;
  var int c;
  c = a + b;
}
```

erzeugt der Compiler diesen Bytecode:

```
0: iconst_5
1: istore_1
2: iload_0
3: iload_1
4: iadd
5: istore_2
6: return
```

Arrays

TECHNISCHE UNIVERSITÄT DARMSTADT

- Arrays werden auf dem Heap verwaltet, lokale Variable enthält nur *Referenz*
- Spezielle Anweisungen zum Erzeugen neuer Arrays:
  - **`newarray`** Erzeugt ein neues Array mit primitiven Elementen
  - **`anewarray`** Erzeugt ein neues Array von Objekten/Arrays
  - **`multianewarray`** Erzeugt ein neues mehrdimensionales Array
- Unser MAVL-JVM-Compiler bildet Vektoren und Matrizen auf Arrays ab (Matrizen werden zu Arrays von Arrays)
- Folgender Code aus dem ASM-Framework erzeugt ein neues Array vom Typ `type`:

```
currentGenerator.newArray(type);
```

Anlegen von Arrays

TECHNISCHE UNIVERSITÄT DARMSTADT

Für MAVL-Vektoren `var vector<int>[5] b`:

```
0: iconst_5
1: newarray       int
3: astore_1
```

Für MAVL-Matrizen `var matrix<int>[3][3] A`:

```
Constant Pool:
#11 = Utf8        [I
#12 = Class       #11
...
4: iconst_3
5: anewarray      #12
```

Anlegen von Arrays

TECHNISCHE UNIVERSITÄT DARMSTADT

MAVL-Matrix wird anschließend noch mit Referenzen auf die Arrays für die einzelnen Zeilen befüllt:

```
15: dup             // Duplizieren der Referenz auf die Matrix
16: iload_3         // Laden des aktuellen Index (Counter)
17: iconst_3        // Laden der Konstante 3
18: newarray int    // Erzeuge neues Array fuer Zeile
20: aastore         // Speichere neues Array an Index in Matrix
```

Das Ganze geschieht in einer Schleife, hier nur ein Ausschnitt des Schleifenkörpers gezeigt

Zugriff auf Array-Elemente

TECHNISCHE UNIVERSITÄT DARMSTADT

- Lesender/schreibender Zugriff auf Elemente eines Arrays mit **<p>aload** bzw. **<p>astore**, wobei **<p>** eines der Präfixe **i,l,f,d,a,b,c,s** sein muss
- Lokale Variable speichert nur Referenz, Laden daher dreistufiger Zugriff:
  1. Laden der Array-Referenz aus lokaler Variable
  2. Ablegen des gewünschten Index auf dem Stack
  3. **<p>aload** konsumiert die beiden Werte und legt stattdessen den gewünschten Wert auf den Stack
- Analoges Vorgehen beim Schreiben, vor Aufruf wird der zu schreibende Wert abgelegt

Zugriff auf Array-Elemente

TECHNISCHE UNIVERSITÄT DARMSTADT

Ausgehend von folgenden MAVL-Deklarationen

```
var vector<int>[5] b;
var vector<int>[3] c;
```

ergibt sich aus `c[1]=b[3]` der folgende Bytecode:

```
8: aload_1    // Laden von Referenz auf b
9: iconst_3   // Index 3
10: iaload    // Laden von b[3]
11: aload_2   // Laden von Referenz auf c
12: swap      // b[3] und Referenz tauschen, b[3] jetzt oben
13: iconst_1  // Index 1
14: swap      // b[3] und Index tauschen, neue Reihenfolge:
              // b[3], Index(1), Referenz auf c
15: iastore   // Speichern in c[1]
```

Arithmetische Operationen

TECHNISCHE UNIVERSITÄT DARMSTADT

- Für alle mathematischen Operatoren in Java gibt es eine Entsprechung auf der JVM
- Alle arithmetischen Operationen arbeiten auf dem Stack
  - Operanden müssen vor der arithmetischen Operation in richtiger Reihenfolge auf dem Stack abgelegt werden
  - Operation konsumiert die entsprechende Zahl von Stackelementen und legt das Ergebnis wiederum als oberstes Stackelement ab
- Integer-Division durch 0 führt zu Exception
- Integer-Rechnung kann zu Overflow/Underflow führen
- Keine Exceptions bei Float-Rechnung, stattdessen Verwendung der IEEE-754-Sonderwerte **`(-)NaN`**, **`(-)Inf`**, etc.

Arithmetische Operationen

TECHNISCHE UNIVERSITÄT DARMSTADT

Für die vier arithmetischen Typen auf der JVM (**`int`**,**`long`**,**`float`**,**`double`**) sind die folgenden binären aritmetischen Operationen definiert

- **`<p>add`**
- **`<p>sub`**
- **`<p>mul`**
- **`<p>div`**
- **`<p>rem`**

Zusätzlich ist noch die unäre Operation

- **`<p>neg`**

definiert, um einen Wert (mathematisch) zu negieren.

Dabei muss **`<p>`** eines der Präfixe **`i,l,f,d`** sein

Logische Operationen

TECHNISCHE UNIVERSITÄT DARMSTADT

Für die beiden ganzzahligen arithmetischen JVM-Typen **`int`** und **`long`** sind zusätzlich die folgenden logischen Operationen definiert:

- **`<p>shl`** Links-Shift
- **`<p>shr`** Arithmetischer Rechts-Shift
- **`<p>ushr`** Logisher Rechts-Shift
- **`<p>and`** Bitweises UND
- **`<p>or`** Bitweises ODER
- **`<p>xor`** Bitweises exklusives ODER

Hier ist die Menge der Präfixe für **`<p>`** auf **`i`** und **`l`** beschränkt

Arithmetische & Logische Operationen

TECHNISCHE UNIVERSITÄT DARMSTADT

Der folgende Code dient zur Erzeugung einer arithmetischen/logischen Operation op auf dem Typ `type`:
`currentGenerator.math(op, type);`
Erzeugter Code:

```
var int a;
var int b;
var float c;
var float d;
val int x = a * b;
val float z = c + d;
```

```
0: iload_1
1: iload_2
2: imul
3: istore       5
5: fload_3
6: fload        4
8: fadd
9: fstore       6
```

Typ-Konversion

TECHNISCHE UNIVERSITÄT DARMSTADT

Im Gegensatz zu Java, wo die Addition eines Float mit einem Int erlaubt ist, gibt es auf der JVM keine impliziten Typ-Konversionen. Deshalb müssen Typen vor einer Rechnung explizit konvertiert werden, dafür stehen die folgenden Operationen zur Verfügung:

- **<s>2<t>** für Konversionen vom Typ **<s>** zu Typ **<t>**, definiert für alle Kombinationen der vier arithmetischen Typen **`int`**, **`long`**, **`float`**, **`double`** mit den Typ-Bezeichnern **`i,l,f,d`**
- **`i2<t>`** für das Abschneiden von Integer-Werten auf einen der drei Storage-Typen **`byte`**, **`char`**, **`short`** mit Typ-Bezeichnern **`b,c,s`**

Bei Konversion von Gleitkommazahlen zu ganzzahligen Werten kommt der sog. *Round-towards-Zero*-Modus zum Einsatz, d.h. $9.6 \rightarrow 9$

Kontrollfluss

TECHNISCHE UNIVERSITÄT DARMSTADT

- Die JVM verfügt über bedingte und unbedingte (**`goto`**) Sprung-Operationen
- Die Abbildung von Kontrollfluss-Konstrukten wie Verzweigungen oder Schleifen funktioniert ähnlich wie Sie das bereits für die TAM kennengelernt haben
- Zur einfacheren Code-Generierung unterstützt das ASM-Framework das Einfügen von Sprungmarken (Labels)

Bedingte Sprünge

TECHNISCHE UNIVERSITÄT DARMSTADT

Die JVM verfügt über zwei Arten von bedingten Sprüngen, beide ausschließlich definiert für **`int`**-Werte.
Die erste Art von bedingten Sprüngen entfernt jeweils nur den obersten Wert vom Stack und betrachtet diesen für die Sprungbedingung:

Anweisung	Beschreibung
`ifeq`	Springe wenn 0
`ifnull`	Springe wenn **`null`**
`iflt`	Springe wenn < 0
`ifle`	Springe wenn ≤ 0
`ifne`	Springe wenn $\neq 0$
`ifnonnull`	Springe wenn nicht **`null`**
`ifgt`	Springe wenn > 0
`ifge`	Springe wenn ≥ 0

Bedingte Sprünge

TECHNISCHE UNIVERSITÄT DARMSTADT

Die zweite Art von bedingten Sprüngen vergleicht die beiden obersten Werte auf dem Stack für die Sprungbedingung

Anweisung	Beschreibung
`if_icmpeq`	Springe wenn $a == b$
`if_icmpne`	Springe wenn $a \neq b$
`if_cmplt`	Springe wenn $a < b$
`if_cmple`	Springe wenn $a \leq b$
`if_cmpgt`	Springe wenn $a > b$
`if_cmpge`	Springe wenn $a \geq b$

Integer Vergleiche

TECHNISCHE UNIVERSITÄT DARMSTADT

Die JVM verfügt abgesehen von den bedingten Sprüngen über keine weiteren Vergleichsoperationen für **`int`**-Werte. Die Berechnung eines Vergleichs wie im folgenden Code muss daher über einen „Umweg“ auf die JVM abgebildet werden.

```
var int a;
var int b;
...
val bool x = a < b;
```

```
0: iload_1
1: iload_2
2: if_icmplt     9
5: iconst_0
6: goto          10
9: iconst_1
10: istore_3
```

Arithmetische Vergleiche

TECHNISCHE UNIVERSITÄT DARMSTADT

Für die Datentypen **`long`**, **`float`** und **`double`** verfügt die JVM über spezielle Vergleichsoperationen (z.B. **`lcmp, fcmpl, dcmpg`**), die zwei Werte vergleichen und als Ergebnis einen der Werte **`0`**, **`-1`** oder **`1`** ablegen. Die Berechnung eines Vergleichs wie im folgenden Code muss auch hier über einen „Umweg“ auf die JVM abgebildet werden.

```
var float c;
var float d;
...
val bool z = c >= d;
```

```
12: fload_1
13: fload_2
15: fcmpl
16: ifge          23
19: iconst_0
20: goto          24
23: iconst_1
24: istore        6
```

Methodenaufrufe

TECHNISCHE UNIVERSITÄT DARMSTADT

- Wie die Auflösung von Methoden-Referenzen funktioniert, haben Sie bereits im Kapitel zum Constant Pool kennengelernt
- Die JVM verfügt über 4 Spezialinstruktionen für den Aufruf von Methoden
  - **`invokevirtual`**
  - **`invokespecial`**
  - **`invokeinterface`**
  - **`invokestatic`**
- Hier Fokus auf **`invokestatic`**, da MAVL-Methoden auf statische Funktionen abgebildet werden
- JVM-Methoden sind nicht zu verwechseln mit *Subroutines*, die mit **`jsr`** und **`ret`** aufgerufen/verlassen werden. Diese werden v.a. für Exception Handling benutzt (hier nicht behandelt)

Routinenprotokoll

TECHNISCHE UNIVERSITÄT DARMSTADT

Das JVM-Routinenprotokoll ist dem Routinenprotokoll der TAM, das Sie bereits kennengelernt haben, sehr ähnlich.

- Die Parameter werden in der richtigen Reihenfolge auf dem Stack abgelegt
- Der Aufruf konsumiert die Parameter vom Stack
- Im Anschluss an den Aufruf liegt ggf. der Return-Wert als oberstes Element auf dem Stack
  - Für den Return steht die Operationen **`<p>return`** mit den möglichen Präfixen **`i,l,f,d,a`** und dem leeren Präfix für **`void`**-Returns zur Verfügung

Einziger größerer Unterschied zwischen JVM und TAM ist, dass Parameter in der JVM automatisch in den Local Variables verfügbar gemacht werden

Methodenaufrufe

TECHNISCHE UNIVERSITÄT DARMSTADT

```
function void bar(int x,
    float y, vector<int>[3]
    z)

function void foo(){
  var int a; var float c;
  var vector<int>[3] v;
  bar(a, c, v);
}
```

```
Constant pool:
#1 = Utf8               A
#2 = Class              #1
#11 = Utf8              bar
#12 = Utf8              (IF[I)V
#13 = NameAndType       #11:#12
#14 = Methodref         #2.#13
```

```
public static void foo(int);
...
0: iconst_3
1: newarray       int
3: astore_3
4: iload_1
5: fload_2
6: aload_3
7: invokestatic  #14
10: return

public static void bar(int,
float, int[]);
flags: ACC_PUBLIC, ACC_STATIC
```

TECHNISCHE UNIVERSITÄT DARMSTADT

Zusammenfassung

Zusammenfassung

TECHNISCHE UNIVERSITÄT DARMSTADT

- Die Java Virtual Machine ist das Herzstück der Java Plattform
- Immer wenn ein Programm in einer der JVM-Sprachen ausgeführt werden soll, muss eine JVM vorhanden sein
- Die Verwendung einer virtuellen Maschine bietet Vorteile gegenüber rein interpretierten oder maschinen-kompilierten Sprachen, z.B. Portabilität und Effizienz
- Zentrale Repräsentation von Programmen ist der JVM Bytecode

Zusammenfassung

TECHNISCHE UNIVERSITÄT DARMSTADT

- Bei der Generierung von Bytecode kann ein Framework wie das ASM-Framework extrem hilfreich sein
- Die drei zentralen Datenstrukturen, auf denen die Operationen arbeiten, sind
  - Local Variables
  - Heap
  - Operandenstack
- Das Vorgehen bei Berechnungen, Kontrollfluss und Methodenaufrufen ähnelt in sehr vielen Aspekten der TAM, da es sich bei der JVM ebenfalls um eine Stack-Maschine handelt