

# Einführung in die Softwareentwicklung

SOMMERSEMESTER 2020



Foliensatz #08

## Module und der Präprozessor

# Der C/C++ Preprozessor



Grundlagen

# Der Präprozessor

## Der Präprozessor – ein Relikt aus C

- Der Präprozessor ersetzt Text in der Eingabedatei
  - Reine Textebene („Tokens“)
    - Namespaces und Gültigkeitsbereiche werden ignoriert
    - Vorrang vor allen C/C++ Regeln
  - Benutzt für einfache „Metaprogrammierung“
    - Programmtext selbst kann „umprogrammiert“ werden
- Ursprünglich: separater Übersetzungsschritt
  - Heute im Compiler eingebaut, läuft automatisch.
  - Manueller Aufruf möglich (hier nur zur Illustration):
    - GNU C Compiler: `gcc -E in.c -o out.i`
    - Microsoft MSVC: `CL /P file.c` (Ausgabe: `file.i`)

# Der Präprozessor

## Der Präprocessor – ein Relikt aus C

- Drei Funktionen
  - Makros ersetzen („`#define`“)
  - Bedingte Übersetzung („`#ifdef`“)
  - Einfügen anderer Dateien („`#include`“)
- Anwendungshinweis
  - Makros sind in C++ weniger wichtig
    - Vermeiden, wann immer möglich
  - Der Rest ist leider immer noch unvermeidbar

# Präprozessor #1

**„#define“**

# Makros

## Beispiele für Makros

```
// Syntax: NAME wird ersetzt durch Text
// Konvention: Makros in Großbuchstaben
#define <NAME> <Text>

// Hier eine beliebige Anwendung (C Standard-Bibliothek definiert so „M_PI“)
#define PI 3.1415926535897932384626433832795
double x = sin(PI*2);

// Eine andere Anwendung
#define NUM_RUNS 128
for (int i = 0; i < NUM_RUNS; i++) {doStuff(i);}

// Eine andere Anwendung
#define ERROR_MSG {cout << "something went wrong!\n";}
if (i != 42) {
    ERROR_MSG
    throw SomeException();
}
```

# Makros

## Beispiele für Makros

// Syntax 2: Parameter in Klammern

```
#define <NAME>(param1, param2, ...) <Text>
```

// Hier eine beliebte aber sehr gefährliche Anwendung

```
#define MAX(a,b) (((a)>(b))?(a):(b)) // Klammern optional – nur zur Sicherheit!
```

```
double x = MAX(23.0, 42.0);
```

// viele C Bibliotheken enthalten #define min()..., #define max() ...

// Eigener Code mit Bezeichner min, max compiliert dann nicht mehr

// Das gilt sogar für viele C++ Standardbibliotheken...

// Eine andere Anwendung (aus unserer eigenen GeoX-Bibliothek): Codegenerierung

```
#define MODULE_REG(moduleName) \ // „Backslash“: Zeilenumbruch Teil des Makros  
    void init_##moduleName () { \ // „##“: Parameter mit Text zu einem Token  
        register_##moduleName(1); \ // verschmelzen  
    }; \  
    void shutdown_##moduleName () { \  
        register_##moduleName(0); \  
    };
```

# Makros – WCPGW?

What could possibly go wrong?

```
// Beliebter Fehler
#define PI 3.1415

// Merkwürdiger Compilerfehler!
void trigometriy(const double PI) {...}
// Erzeugt Code: void trigometriy(const double 3.1415) {...}
// Compiler is not amused. Fehler oft schwer zu finden!

// Das funktioniert, da Ersetzung „Tokenweise“ (ganze Wörter)
void calc_PI() {...}
```

## Textuelle Ersetzung

- Gefährlich – Text wird einfach ersetzt
  - „Token“-weise: Getrennt durch Whitespaces oder Sonderzeichen
- Ersetzung greift ab `#define`
  - Gültigkeitsbereiche (`{}`, `namespace` etc.) wirkungslos

# In C++: Makros vermeiden

## Makros vermeiden

// Bessere Konstanten (sicherer, aber nur in C++ möglich)

```
const double PI = 3.1415926535897932384626433832795;
```

// Kein Compilerfehler mehr – voller Scope & Type-Check!

```
void trigometriy(const double PI) {...}
```

// Bessere Code-Makros (sicherer, genauso schnell)

```
inline double max(double a, double b) {return (a>b) ? a : b;}
```

// Generische Version (beliebige Typen) auch möglich!

// Compiler prüft, dass die beiden Typen für a, b gleich sind!

// Kein Geschwindigkeitsunterschied zum Makro zur Laufzeit!

```
template <typename T>
```

```
inline T max(T a, T b) {return (a>b) ? a : b;}
```

# Präprozessor #2

**„#ifdef“**

# Bedingte Compilierung

## Syntax für bedingte Compilierung

// Syntax: #ifdef, #else, #endif

```
#ifdef <NAME>
```

```
    <code> // Falls NAME definiert ist
```

```
#else // optional!
```

```
    <code> // Falls NAME nicht definiert ist
```

```
#endif
```

// Syntax: #ifndef, #else, #endif

```
#ifndef <NAME>
```

```
    <code> // Falls NAME nicht definiert ist
```

```
#endif
```

// Setzen & löschen des „booleschen“ Makros (auch per Compiler-Option möglich)

```
#define <NAME> // ab hier sicher definiert
```

```
#undef <NAME> // ab hier sicher nicht mehr definiert
```

# Bedingte Compilierung

## Beispiel für bedingte Compilierung

```
// Debugging ein/ausschalten
void zero_array(vector<double> a, unsigned numZeros)

#ifdef _DEBUG // Die meisten Compiler setzen dies im Debug Modus

    if (numZeros >= a.size()) {
        throw OutOfRangeException("That almost went wrong!");
    }

#endif

for (unsigned i=0; i<a.size(); a++) {
    a[i] = 0.0;
}
}
```

## Code nur für „Debug“-Modus

- Nützlich: Stärkere Prüfungen zur Fehlersuche
- Volle Geschwindigkeit bei „Release“-Build

# Bedingte Compilierung

## Beispiel für bedingte Compilierung

```
#define USING_64_BIT_CPU // switch to 64-Bit Code

void fast_zero_memory(uint8_t *buffer, unsigned size) {
    #ifndef USING_64_BIT_CPU
        uint64_t i;
        for (i = 0; i < size/8; i++) {
            *buffer[i] = 0;
        }
        uint64_t rest = size % 8;
    #else
        uint32_t i;
        for (i = 0; i < size/4; i++) {
            *buffer[i] = 0;
        }
        uint32_t rest = size % 4;
    #endif
    for (unsigned j=0; j < rest; j++) {
        buffer[i+j] = 0;
    }
}
```

# Bedingte Compilierung

## Beispiel für bedingte Compilierung

```
#define USING_AVX2 // switch to vectorized code using Intel AVX-2 Extensions

void fast_zero_memory(uint8_t *buffer, unsigned size) {
    #ifdef USING_AVX2
        uint64_t i; const __m256i ZERO = _mm256_set_epi64(0,0,0,0,0,0,0,0);
        for (i = 0; i<size/32; i++) {
            *((__m256i*)buffer)[i] = ZERO;
        }
        uint64_t rest = size % 32;
    #else
        uint64_t i;
        for (i = 0; i<size/8; i++) {
            *buffer[i] = 0;
        }
        uint64_t rest = size % 8;
    #endif

    for (unsigned j=0; j<rest; j++) {
        buffer[i+j] = 0;
    }
}
```

### Anmerkung:

Auf modernen CPUs macht 32/64Bit Zugriff keinen oder kaum einen Unterschied.

Optimierungen dieser Art sind aber für Vektorisierung mit AVX o.ä. nützlich.

# Präprozessor #3

## „**#include**“

# #include

Datei: definitions.h

```
#define M_PI 3.1415926535897932384626433832795

inline double max(double a, double b) {
    return (a>b) ? a : b;
}

void printHelloWorld() {
    std::cout << "Hello World!";
}
```

Datei: main.cpp

```
#include <iostream>          // <...> = Look in path with standard libraries first
#include "definitions.h"    // ".." = Look in current directory first (use for own libraries)

int main() {
    std::cout << M_PI << "\n";
    std::cout << max(23, 42) << "\n";
    printHelloWorld();
}
```

# #include

## Includes

- `#include "Datei.h"`
- Präprozessor fügt Datei wortlich ein
- Konvention: Dateiname endet mit „.h“

## Gleiche Wirkung wie abtippen!

- `#defines`, `#ifdefs`, etc. wirken weiter
- Keine Prüfung von Namensräumen
- Rekursive `#includes` möglich (Compiler-Absturz!)

# #include

Datei: MyMathTools.h

```
#include "Definitions.h"  
  
inline double max(double a, double b) {  
    return (a>b) ? a : b;  
}
```

Datei: Definitions.h

```
#include "MyMathTools.h"  
  
#define M_PI 3.1415926535897932384626433832795  
  
#define USING_AVX2
```

## Zyklische Abhängigkeiten nicht erlaubt!

- „#include“ einer der beiden obigen Dateien in einem CPP-File führt zu Compiler-Crash!
- Vermeidung mit „include-guards“ (ja, auch im Jahr 2018...)

# #include-Guards

Datei: MyMathTools.h

```
#ifndef MYMATHTOOLS_H // Hope & pray that nobody #defines this symbol elsewhere!  
#define MYMATHTOOLS_H // Typo-risk (I always copy & paste this symbol !!)  
  
#include "Definitions.h"  
  
inline double max(double a, double b) {  
    return (a>b) ? a : b;  
}  
  
#endif // Do not forget!!! (weirdest compiler errors)
```

Datei: Definitions.h

```
#ifndef DEFINITIONS_H  
#define DEFINITIONS_H  
  
// Still impossible to include "Defintions.h" cyclically  
// It will just not work / do what its seems to do (no error message from compiler. good luck.)  
  
#define M_PI 3.1415926535897932384626433832795  
#define USING_AVX2  
  
#endif
```

# #pragma once (nicht Standard)

Datei: MyMathTools.h

```
#pragma once // supported by most compilers, but non-standard

#include "Definitions.h"

inline double max(double a, double b) {
    return (a>b) ? a : b;
}
```

Datei: Definitions.h

```
#pragma once // supported by most compilers, but non-standard

// Also in this case: still impossible to include "Defintions.h" cyclically
// Same problems as in guarded case.

#define M_PI 3.1415926535897932384626433832795
#define USING_AVX2
```

## Erläuterung

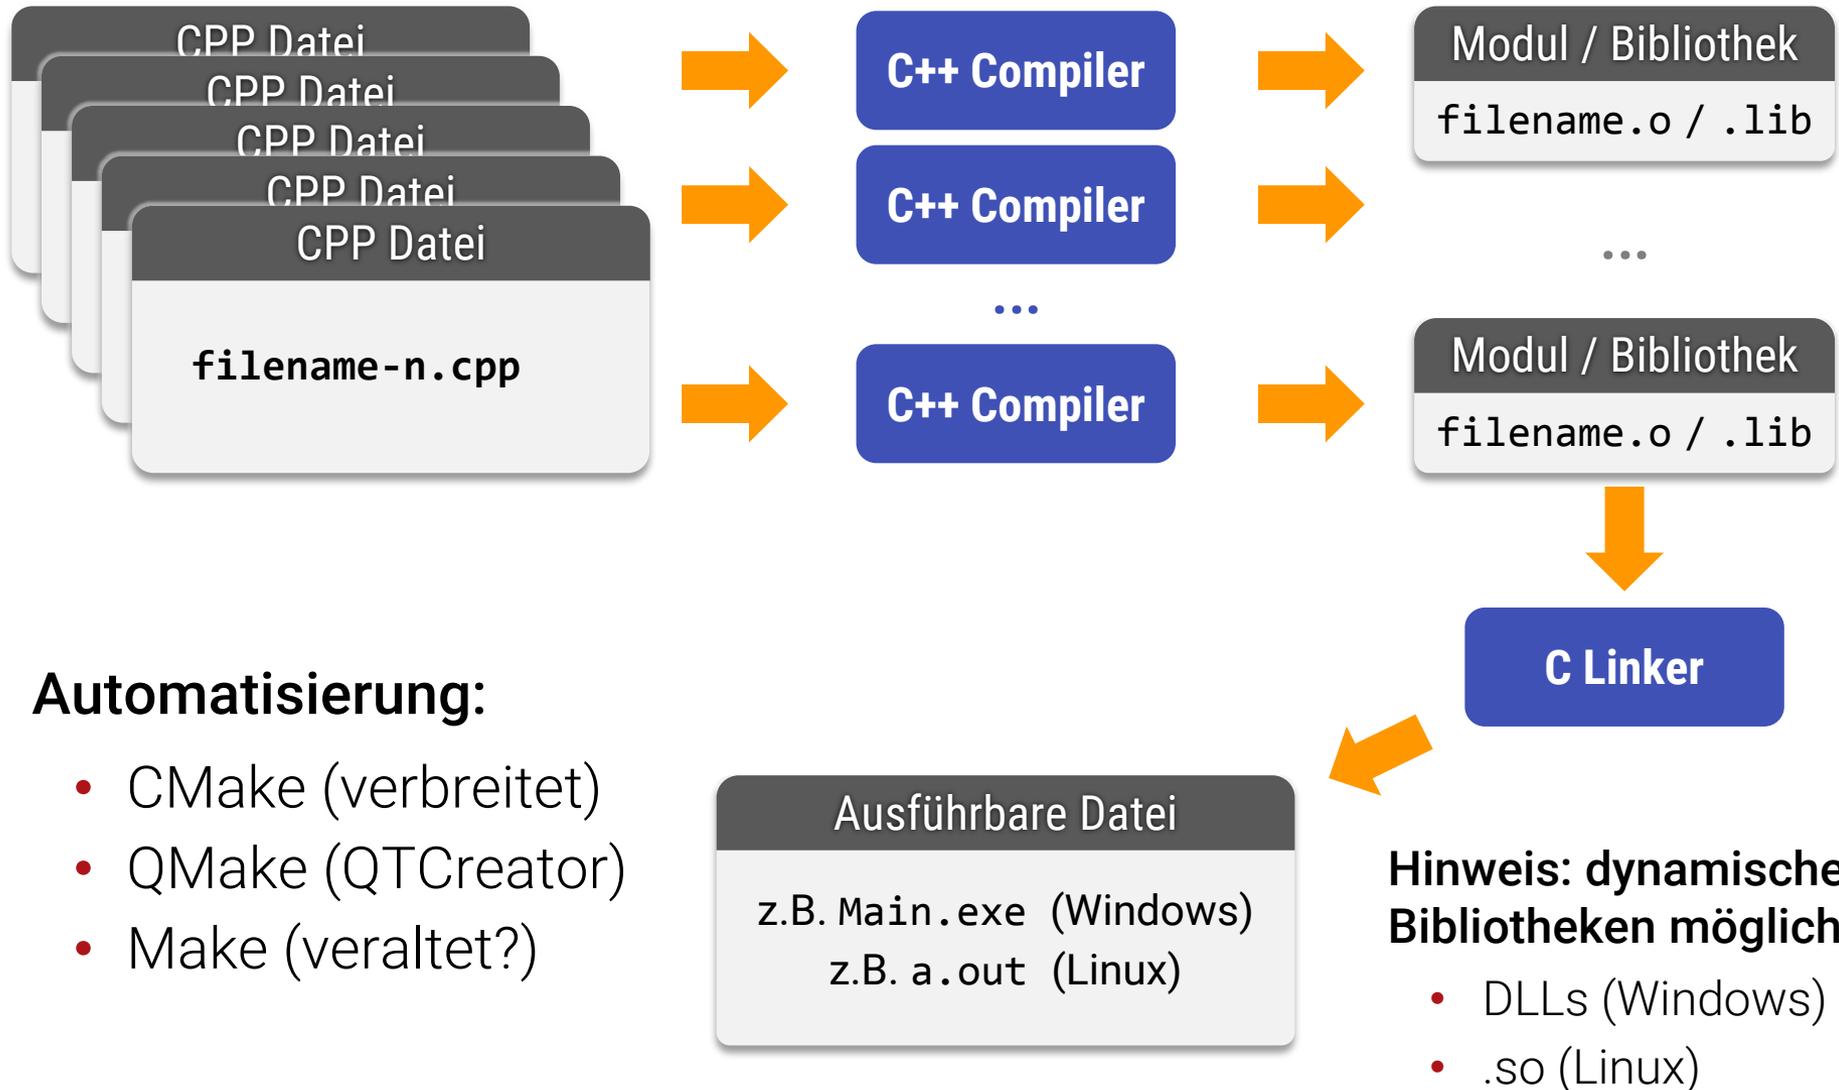
- #pragma generell: „nicht standartisierte“ Hinweise an Compiler
- #pragma **once** heißt: Datei nur einmal #includen pro Comp.-Lauf

# Separate Übersetzung



fortgeschritten

# Übersetzung: Komplexes System



# Prinzipien

## Zwei Teile einer Bibliothek

- **Interface („Schnittstelle“)**

Alle Informationen, die zum Verwenden einer Bibliothek gebraucht werden

- Signaturen von Funktionen
- Typinformationen (teilweise)
  - Name, Membersignaturen, ggF. Details

- **Implementation**

Weitere Informationen, die zum Übersetzen/Erstellen der Bibliothek selbst gebraucht werden

- Code aller Funktionen
- Genaue Typinformationen

# Wie man es richtig macht

## Sehr einfach

- Interface als eine Datei
- Implementation als gesonderte Datei
- Beides wird übersetzt
  - Übersetztes Interface:  
Für Benutzung durch Compiler
  - Übersetzte Implementation:  
Für Linker (Code zum Zusammenbauen)
- C/C++ kann das leider (noch) nicht :-)

# Beispiel (Modula 2)

Datei: IntegerLists.def

```
DEFINITION MODULE IntegerLists;  
  
TYPE IntList; (* Opaker Typ – Details nicht öffentlich bekannt *)  
  
FUNCTION createList() : POINTER TO IntList;  
EXPORTS createList, IntList;  
  
END.
```



Compiled Interface  
IntegerLists.sym

Datei: IntegerLists.mod

```
MODULE IntegerLists;  
  
FROM Storage IMPORT ALLOCATE, DEALLOCATE;  
  
TYPE IntList = RECORD  
  memory: POINTER TO Integer;  
  size: Integer;  
END;  
  
FUNCTION createList() : POINTER TO IntList;  
VAR result: POINTER TO IntList;  
BEGIN  
  ALLOCATE(result, TSIZE(IntList));  
  result^.size = 0; result^.memory = NIL;  
  RETURN result;  
END;  
  
BEGIN END. (* Hauptprogramm ist hier leer *)
```



Compiled Implementation  
IntegerLists.obj

## Achtung:

In C++ heißen Interfaces „Deklarationen“ und Implementationen „Definitionen“.

# Übersetzung

## **Wenn Modul benutzt wird**

- `.sym` Dateien aller benutzter Bibliotheken werden benötigt

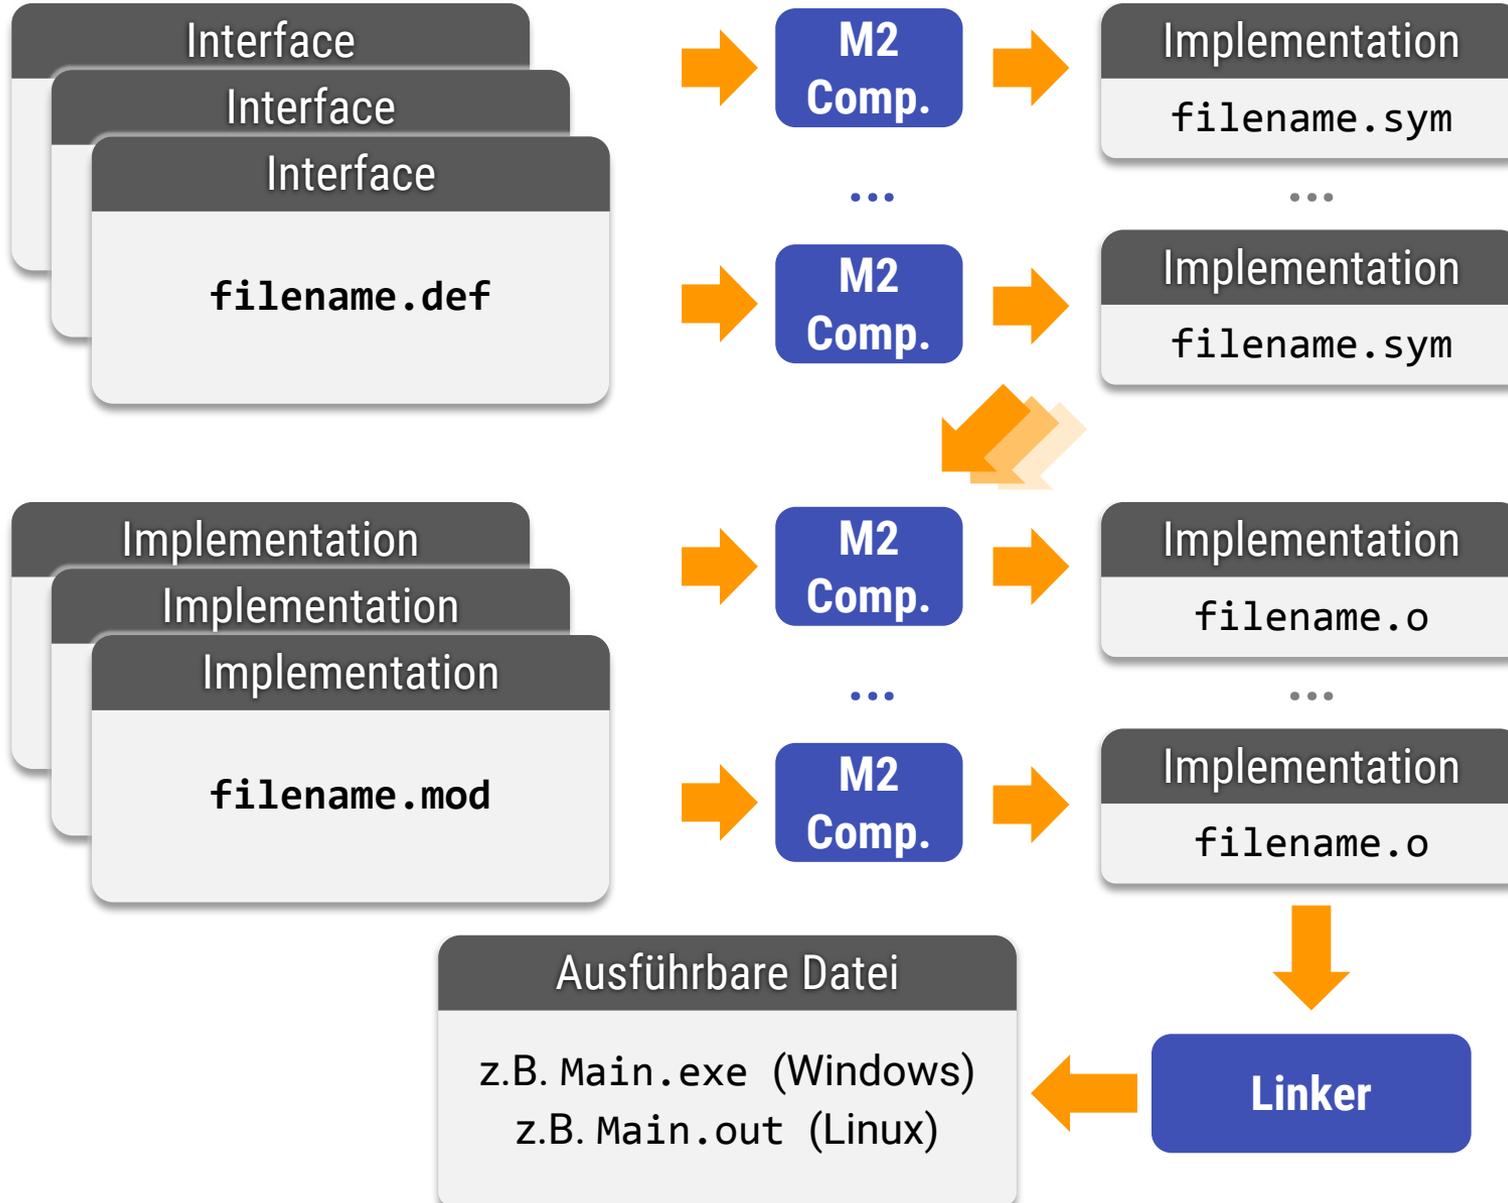
## **Zum Linken des gesamten Programms**

- Alle `.obj` Dateien werden benötigt

## **Jedes Modul wird getrennt übersetzt**

- (sehr!) schnell
- Saubere Trennung von Schnittstelle & Implementation
- Keine Seiteneffekte, expliziter Export/Import

# Übersetzung Komplexer Systeme



# JAVA / Python

## Andere Sprachen

- Java, Python, Borland / Object Pascal
- Eine Datei für Interface und Implementation
  - Bei Pascal mit zwei Abschnitten
  - Bei Python und Java nur volle Implementation
- Compiler übersetzt Interfaceanteil und Implementation automatisch in getrennte Dateien

## Vorteil:

- Weniger Tipparbeit, trotzdem schnelle Übersetzung

## Nachteil:

- Interface nicht (so) sauber getrennt

# Weiterentwicklungen

## Java Virtual Machine

- Genormte Module (.class) für alle Plattformen und Prozessoren
  - Zwischencode („virtual machine“)
  - Übersetzung in Maschinensprache bei Bedarf (JIT)

## Microsoft .net Framework

- Genormte Module wie bei JVM
  - „Assemblies“ in Zwischencode oder Binärcode
  - Übersetzung ahead-of-time oder just-in-time (JIT)
- Versionierung, Metadaten, etc.

# Definition vs. Deklaration

## **Schnittstelle: Deklaration** (C++ Sprachgebrauch)

- Wird nur vom Compiler gesehen
- Deklaration von Typen
- Deklaration von Funktionen ohne Code
- Deklaration von globalen Variablen als „extern“

## **Implementation: Definition** (C++ Sprachgebrauch)

- Wird vom Linker geprüft
- Deklaration von Funktionen mit Code
- Globalen Variablen ohne „extern“
- Darf nur 1x auftauchen (sowohl Compiler & Linker!)

# „Best Practices“

(es gibt ja keine Module)



fortgeschritten

# Beispiel (C++)

Datei: MyMathTools.h

```
#ifndef MYMATHTOOLS_H // Include-guard!  
#define MYMATHTOOLS_H  
  
#include <cstdint> // Interfaces anderer Module – Textuelle Ersetzung!  
  
double max(double a, double b); // Deklaration, keine Definition  
  
uint64_t max(uint64_t a, uint64_t b); // Deklaration, keine Definition  
  
#endif // Include-guard!
```

 Wird nicht vorab übersetzt (bei jeder Benutzung von Neuem)

Datei: MyMathTools.cpp

```
#include "MyMathTools.h" // Immer als erstes eigenes .h-File includen!!  
#include <stdio> // Interfaces anderer Module, nur für Implementation  
  
double max(double a, double b) { // Definition! (Implementation)  
    return (a>b) ? a:b;  
}  
  
uint64_t max(uint64_t a, uint64_t b) {...}
```

 **Compiled Implementation**  
IntegerLists.obj

# Deklarationen in C++ (.h Files)

## (Wichtige) erlaubte Deklarationen

- // Funktionsdeklaration  
**void** someFunction(int a, int b);
- // Typdeklaration  
**struct** SomeClass {  
    int a; int b;  
};
- // Opake Typdeklaration (Damit nur Zeiger möglich!)  
**struct** SomeClass;
- // Variablendeklarationen  
**extern** int a;

# Definitionen (.cpp Files)

## Dazu passende Definitionen

- // Funktionsdefinition  
`void someFunction(int a, int b) {  
 ...some code...  
}`
- // Variablendefinitionen  
`int a;`
- // Mit Wert initialisierte Variablen sind immer Definition  
`int a = 42;`

# Deklarationen von Klassen

Datei: `IntList.h`

```
// (Include guards dazudenken!)
struct IntList {
    int *memory;
    int size;
    // Konstruktor
    IntList(unsigned initialSize = 0);
    // Destruktor (bei Löschen des Objektes)
    ~IntList(unsigned initialSize = 0);
    // Zugriff auf Elemente
    int &operator[](unsigned index);
};
```

## Klassendeklarationen (**.h-File**)

- Code auslassen!
  - Man kann ihn auch direkt reinschreiben, ist schlechter Stil
  - Probleme mit Abhängigkeiten, außerdem: „implicit inline“

# Deklarationen von Klassen

Implementation: `IntList.cpp`

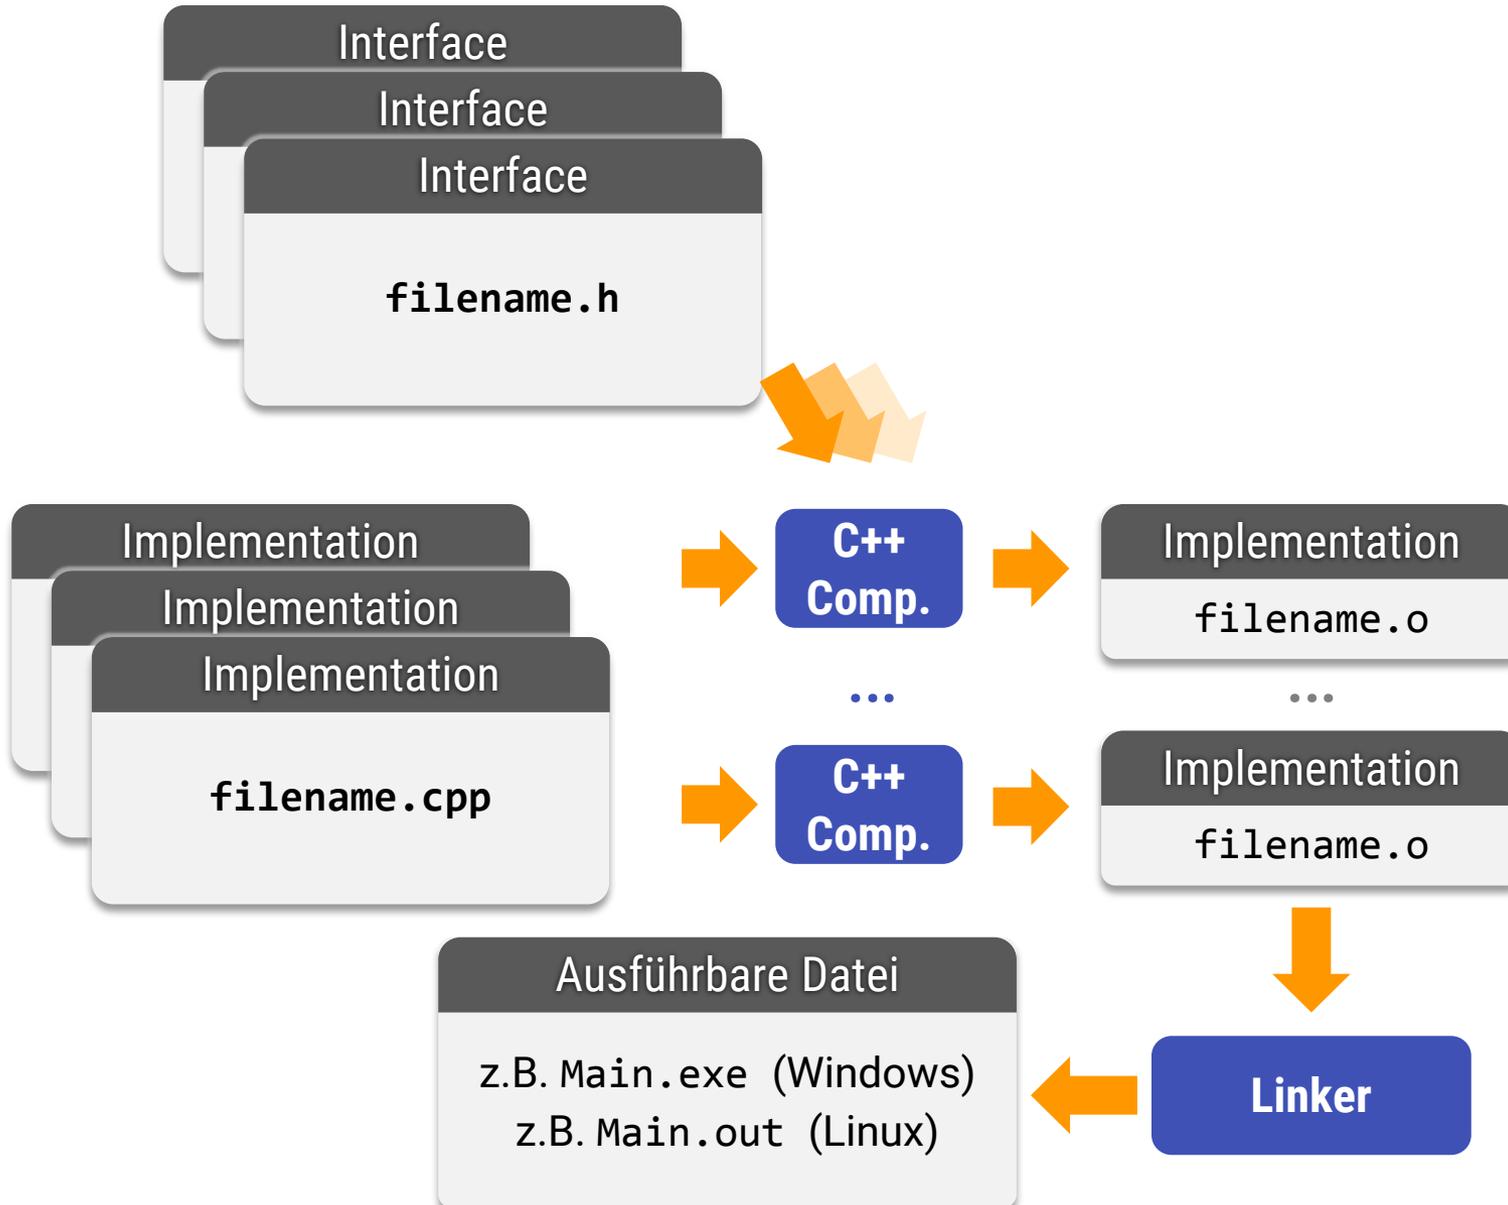
```
IntList::IntList(unsigned initialSize = 0) {
    memory = new int[initialSize]; // Speicher reservieren (0 erlaubt)
    size = initialSize;
}

IntList::~IntList(unsigned initialSize = 0) {
    delete[] memory; // Speicher freigeben
}

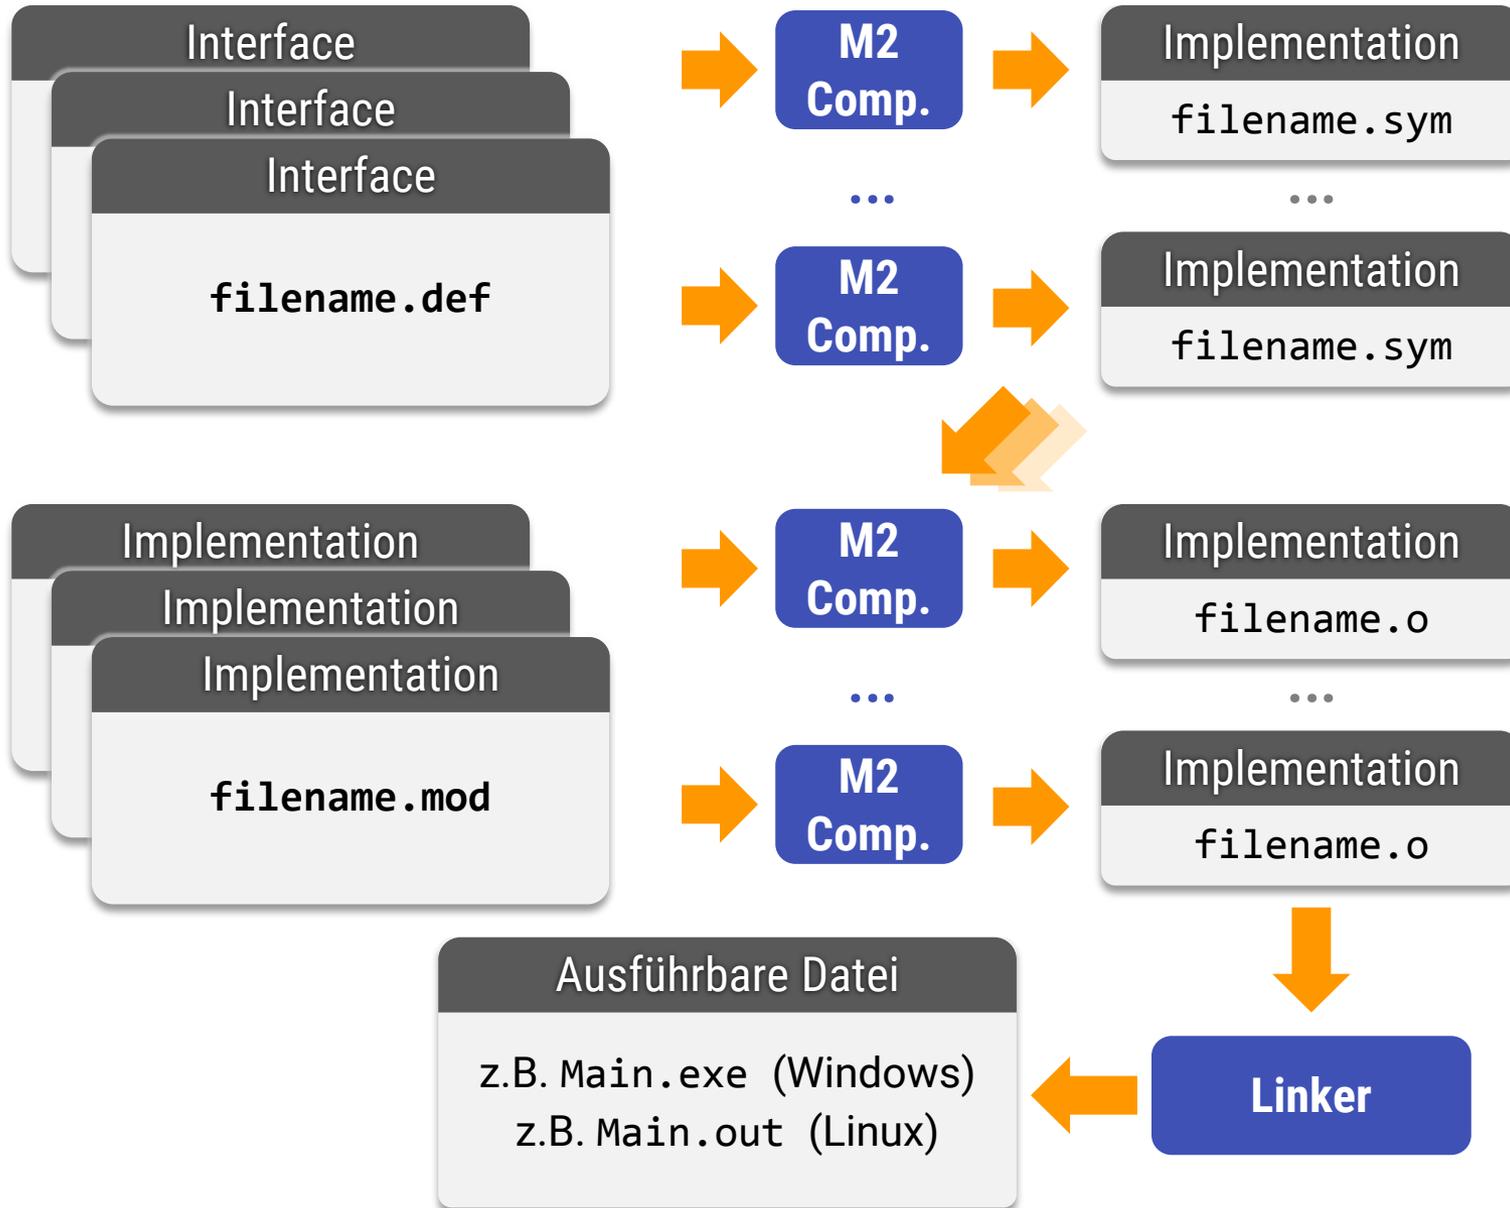
int &IntList::operator[](unsigned index) {
    if (index >= size) {
        throw std::out_of_range("out of bounds");
    }
    return memory[index];
}
```

**Definitionen getrennt! (.cpp-File)**

# Übersetzung in C++



# Übersetzung in Modula-2 u.ä.



# Best Practices

## Probleme beim Modulsystem

- C++-Module werden textuell eingefügt
- Durch **#define** können Seiteneffekte auftreten
  - Reihenfolge von **#include** kann eine Rolle spielen
  - Semantik eines Modul ändert sich durch Verwendung eines anderen
  - *<<Schauder>>* – dies sollte eigentlich verboten sein
  - Weil es aber so definiert ist, kann man **#includes** nicht getrennt übersetzen
- Seiteneffekte unbedingt vermeiden!
  - **#define** sehr sparsam verwenden
  - Global eindeutige Namen (vor allem für include-guards!)

# Best Practices

## Übersetzungszeiten

- C++ Übersetzt sehr langsam
- Wenn jedes Modul alle anderen `#included`, steigt der Aufwand quadratisch mit der Projektgröße
- Hauptgrund für lange Übersetzungszeiten!

## Milderung

- Abhängigkeiten Minimieren
  - So wenige `#includes` anderer Module wie möglich
- Opake Typdefinition „`struct Typ;`“, „`class Typ;`“ wann immer möglich (statt `#include` der Deklaration)

# Best Practices

## Zyklische Abhängigkeiten

- Headerfiles können/dürfen nicht zyklisch abhängig sein
- `.cpp`-Files binden nur `.h`-Files ein – Zyklen unmöglich
- Auflösung per Hand  
(z.B. opake Deklaration für Zeigertypen)

# inline / templates

## Noch eine Schwierigkeit

- inline-Code muss im Header stehen!
- Binärbibliotheken von C++ unterstützen kein inline (da C-kompatibel)
- Das gilt auch für template code aller Art!!!
  - Macht viel Ärger
  - z.B. bei zyklischen Abhängigkeiten (google template-rebinding)

# Name Mangeling

## Und noch eine... :-)

- Der Linker ist ein C-Linker
  - Linker kennt keine C++-Features
- Daher „Name-Mangling“ für Überladen + Klassen
  - Namen werden ersetzt für Eindeutigkeit
  - Ersetzungsschema ist nicht „Human-friendly“
  - Linker-Fehlermeldungen oft unverständlich
  - Name Mangeling kann mit  
„extern "C" {...Deklarationen...}“  
abgeschaltet werden (auch bei Übersetzung von .c files)

**(Hätte man doch von Modula-2 gelernt...)**

# Die Python/C++-Plattform

## Genormte ABIs für C (nicht C++)

- „`ccall`“ definiert für jede OS+CPU-Kombination
  - Aufruf von Funktionen mit C-features
  - Keine C++-Konstrukte
    - Compiler nutzen C-Abbildung via Name-Mangling
    - Abbildung nicht genormt
- Statisch (`.lib`) und dynamisch ladbar (`.so/.dll`)

## Python

- Module im Quelltext
- Interpretation (precompile) bei ersten Laden
- Einbindung von C-Dlls, z.B. „`ctypes`“ (C), „`pybind`“ (C++)

# Aber wie geht es in C++?

## C++ kennt keine Module

- Statt dessen: teilweise Übersetzung

## Was heißt das?

- Man kann Code weglassen
- Funktionen fehlen dann in Binärdatei
- Linker fügt alles am Ende zusammen

## Regel

- Implementation **muss genau 1x** vorhanden sein
- Sonst Fehler (Linkerfehler / Compilerfehler)

# C++ 20 Current Draft

(Ab May '20 gibt es nun  
doch Module...)



Vertiefung

# Beispiel (C++20 / CLANG)

Datei: MyMathTools.cppm

```
export module MyMathTools; // Module interface: MyMathTools.cppm

export double max(double a, double b); // Deklaration
export uint64_t max(uint64_t a, uint64_t b); // Deklaration
```

Datei: MyMathTools.cpp

```
module MyMathTools; // Module implementation: MyMathTools.cpp

double max(double a, double b) { // Definition! (Implementation)
    return (a>b) ? a:b;
}

uint64_t max(uint64_t a, uint64_t b) {...}
```

Datei: main.cpp

```
import MyMathTools; // Benutzung z.B. in Hauptprogramm main.cpp

int main() {
    cout << max(23, 42);
}
```

# Details tbd.

## Fehlende Details

- Genaue Regeln für „**export**“, Interfaces, Implementationen, Teilmodule (parts)
- Kompatibilität mit „Include“
- Übersetzungsprozess

## Offene Baustellen

- Compilersupport – noch in Entwicklung
- (Derzeit?) Probleme mit Geschwindigkeit, Parallelität
- C++20 sieht noch kein stabiles ABI (application binary interface) vor – gleiche Compilerversion nötig