[1)]

Texterzeugung mit Herrn Markow

Ein Markow-Prozess - benannt nach dem russischen Mathematiker Andrei Andrejewitsch Markow - ist ein mathematisches Modell, das verwendet wird, um die zukünftige Entwicklung eines Systems vorherzusagen. Es basiert auf der Idee, dass die zukünftige Entwicklung des Systems nur von seinem aktuellen Zustand abhängt und nicht von seiner gesamten Vergangenheit.

Nonsense-Texterzeugung

Wir können einen Markow-Prozess verwenden, um vorherzusagen, welche Buchstaben(folge) als nächstes ausgegeben werden soll, basierend auf dem aktuellen Buchstaben(folge) im Text.

Einen solchen Markow-Prozess kann man sich sehr gut als Graph veranschaulichen:

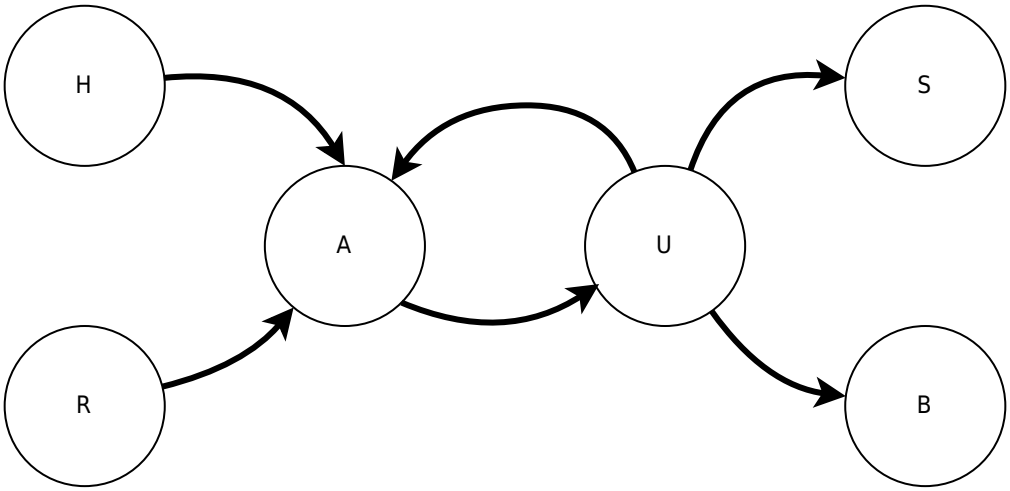

Man beginnt bei einem beliebigen Buchstaben, die Pfeile des gerichteten Graphen geben die erlaubten Übergänge an. So kann man Worte bilden, die gewissen Regeln unterliegen - die erlaubten nächsten Buchstaben hängen davon ab, was der gerade aktuelle Buchstabe ist.

- HAU
- LAU
- LAUB
- RAUB

- RAUS
- HAUS
- AUA
- UAUB

Sind "erlaubte" Worte, die so erzeugt werden können.

Die tatsächlich gewählten Übergange sind dabei **zufällig**, die so erzeugten Worte unterliegen also den Regeln welche der Graph vorgibt, es ist aber gleich wahrscheinlich, ob nach einem U ein B, ein S oder ein A angefügt wird.

Ausprobieren

Das BlueJ-Projekt "Markow-Texter" erlaubt es, einen solchen Textgenerator auszuprobieren und zu untersuchen.

Lade das Bluej-Projekt herunter[2]. Um das Programm zu verwenden, öffnet man das BlueJ-Projekt und führt die JavaFX Anwendung aus, indem man mit der rechten Maustaste auf die Klasse "MarkowFX" klickt und im Menü den Punkt "Run JavaFX Application" auswählt - dann sollte sich das Programmfenster öffnen:

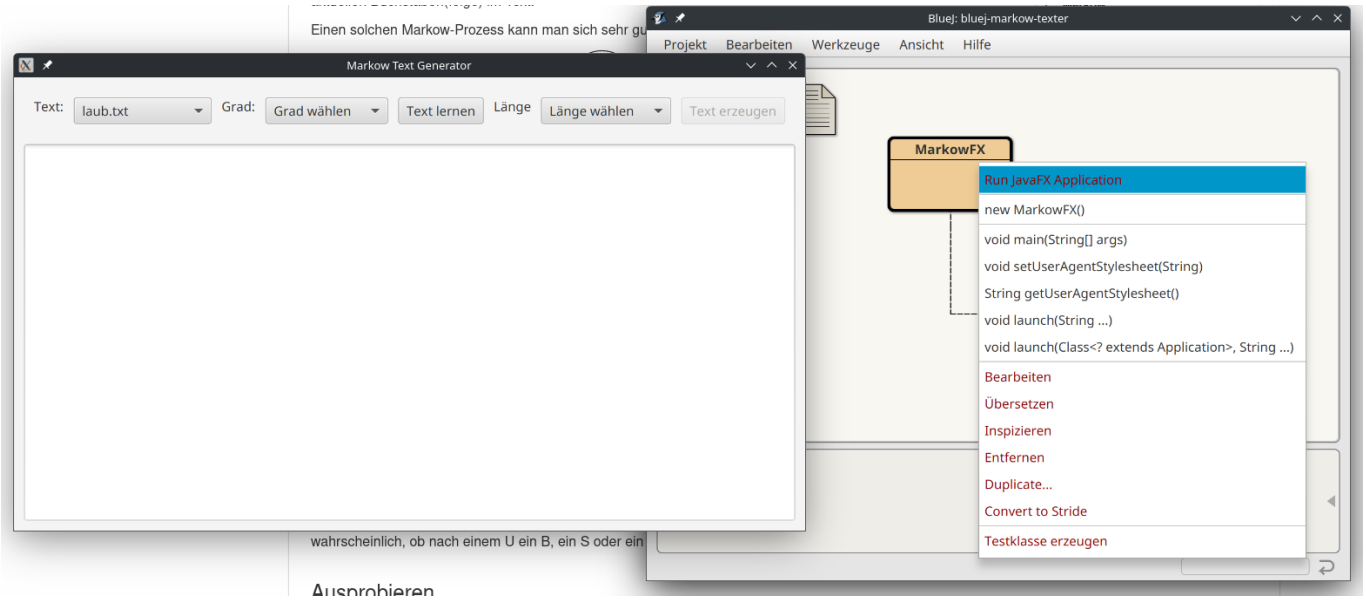

(A1)

Teste das Programm mit der "Trainingsdatei" `laub.txt`.

Wichtig: Beim einlesen des Trainingstextes werden alle Zeichen in Kleinbuchstaben konvertiert, paarige Zeichen wie Anführungszeichen entfernt und Zeilenumbrüche durch ein großes "N" ersetzt.

- Wähle als Grad 1
- Klicke dann auf `Text lernen`
- Analysiere die Ausgabe im Textfeld. Notiere, was diese Bedeuten könnte.
- Wähle als Textlänge 40 Zeichen
- Klicke anschließend auf `Text erzeugen`

Wie funktionierts?

Die Funktionalität des Markow Texters findet sich in der Klasse `Markow`[3].

Die wichtigsten Bestandteile:

`uebergaenge`: Das ist eine HashMap, das den Übergangsgraphen speichert. Dort wird festgehalten, welche Folgezeichen zu einem aktuellen Zustand erlaubt sind.

```
private Map<String, Map<Character, Integer>> uebergaenge;
```

Beim Lernen des Texts wird hier z.B. folgendes eingetragen:

```
"a": u(6) N(2)
```

Das bedeutet, dass `uebergaenge["a"]` eine Liste von Zeichen mit ihrer zugehörigen Häufigkeit enthält, mit der sie im Anschluss an "a" aufgetreten sind: Das Zeichen "u" folgte 6 mal auf ein "a", ein Zeilenumbruch ("N") folgte 2 mal auf ein "a".

(A2)

Erhöhe den Grad auf 2 und lerne erneut den Text `laub.txt`. Interpretiere die Ausgabe des Lernprozesses. Der Text findet sich im Unterverzeichnis `texte` des Projekts. Öffne die Datei `laub.txt` mit einem Editor und überprüfe deine Ideen.

Lösungshinweis

```
"au": a(2) b(2) s(2)
"Nr": a(3)
"la": u(1)
"ha": u(2)
"Nh": a(2)
"sN": h(2)
"bN": r(2)
"ua": N(2)
"ub": N(2)
```

- https://www.info-bw.de/

```
"aN": r(1)
"us": N(2)
"ra": u(3)
```

Nun wird jeweils gespeichert, wie häufig ein Zeichen auf ein Zeichenpaar im Text folgt. z.B.

```
"bN": r(2)
```

Auf die Zeichenkombination b + Zeilenumbruch folgte 2 mal ein r.

Teste weitere Grade beim Lernen des Textes.

Die Methoden `lerneText(String textQuelle, int grad)` und `lerneUebergang(String letzteZeichen, char naechstesZeichen)`:

```
/**
 *   Lerne Text
 */
public void lerneText(String text, int grad) {
    this.grad = grad;
    uebergaenge.clear();

    for (int i = 0; i < text.length() - grad; i++) {
        // Hier wird das "Zustandsfenster" der Länge grad
        // über den Text "geschoben"
        String zustand = text.substring(i, i + grad);
        // Das ist das Zeichen, das auf den aktuellen Zustand folgt
        char naechstesZeichen = text.charAt(i + grad);
        // Lerne den gefundenen Übergang
        lerneUebergang(zustand, naechstesZeichen);
    }
}

/**
 * Hier wird ein gefundener Übergang überprüft und
 * passend in der HashMap eingetragen
 */
public void lerneUebergang(String zustand, char naechstesZeichen) {
    // Versuche die Übergangs-Map für den aktuellen Zustand zu lesen
    Map<Character, Integer> folgeZeichenMap = uebergaenge.get(zustand);
    // Wenn es für den Zustand noch keine Einträge gibt...
    if(folgeZeichenMap == null) {
       // Zuerst eine neue Map für die Folgezeichen anlegen. Die ist erst
mal leer...
       uebergaenge.put(zustand, new HashMap<>());
    }
    // Jetzt gibt es für den Zustand auf alle Fälle ein Map mit den
```

```
Folgezeichen
    // Nun muss man entscheiden, ob das aktuelle Folgezeichen neu da rein
muss
    // oder ob nur seine Anzahl erhöht werden muss.
    folgeZeichenMap = uebergaenge.get(zustand);
    Integer anzahl = folgeZeichenMap.get(naechstesZeichen);
    if(anzahl == null || anzahl == 0) {
        folgeZeichenMap.put(naechstesZeichen, 1);
    } else {
        folgeZeichenMap.put(naechstesZeichen, anzahl + 1);
    }
    uebergaenge.put(zustand, folgeZeichenMap);
}
```

(A3)

Vollziehe am Wort `kakaopulver` mit dem Grad 2 nach, was die beiden Methoden machen. Welche Übergänge sind am Ende des Lernprozesses in der HashMap `uebergaenge` abgelegt?

Du kannst das mit dem Markow-Texter überprüfen, indem du den Text `kakaopulver` in die Datei `experiment.txt` einträgst und das Programm lernen lässt.

Hilfestellung: Schritt 1

Textlänge ist 11, Grad ist 2
die Schleife läuft also bis einschließlich Index 8 (9 ist nicht mehr dabei, wegen des < Zeichens)

"zustand" ist "ka" -> text.substring(0,2) also mit 0, aber ohne das Zeichen mit Index 2. Das nächste Zeichen ist "k".

Gibt es einen Eintrag für "ka"? -> Nein!
Also leere Liste mit Folgezeichen für "ka" anlegen.
Ist "k" dort vermerkt - natürlich nicht
Also die Zuordnung "k"|1 in der Liste der Folgezeichen ablegen, weil "k" 1x als Folgezeichen zu "ka" aufgetaucht ist.

uebergaenge:

"ka" -> "k"|1

Nach dem ersten Schritt

Hilfestellung: Schritt 2

uebergaenge:

"ka" -> "k"|1

i rückt 1 weiter...

"zustand" ist "ak" -> text.substring(1,3) also mit 1, aber ohne das Zeichen mit Index 3. Das nächste Zeichen ist "a".

Gibt es einen Eintrag für "ak"? -> Nein!
Also leere Liste mit Folgezeichen für "ak" anlegen.
Ist "a" dort vermerkt - natürlich nicht
Also die Zuordnung "a"|1 in der Liste der Folgezeichen ablegen, weil "a" 1x als Folgezeichen zu "ak" aufgetaucht ist.

uebergaenge:

"ka" -> "k"|1

"ak" -> "a"|1

Nach dem zweiten Schritt

Hilfestellung: Schritt 3

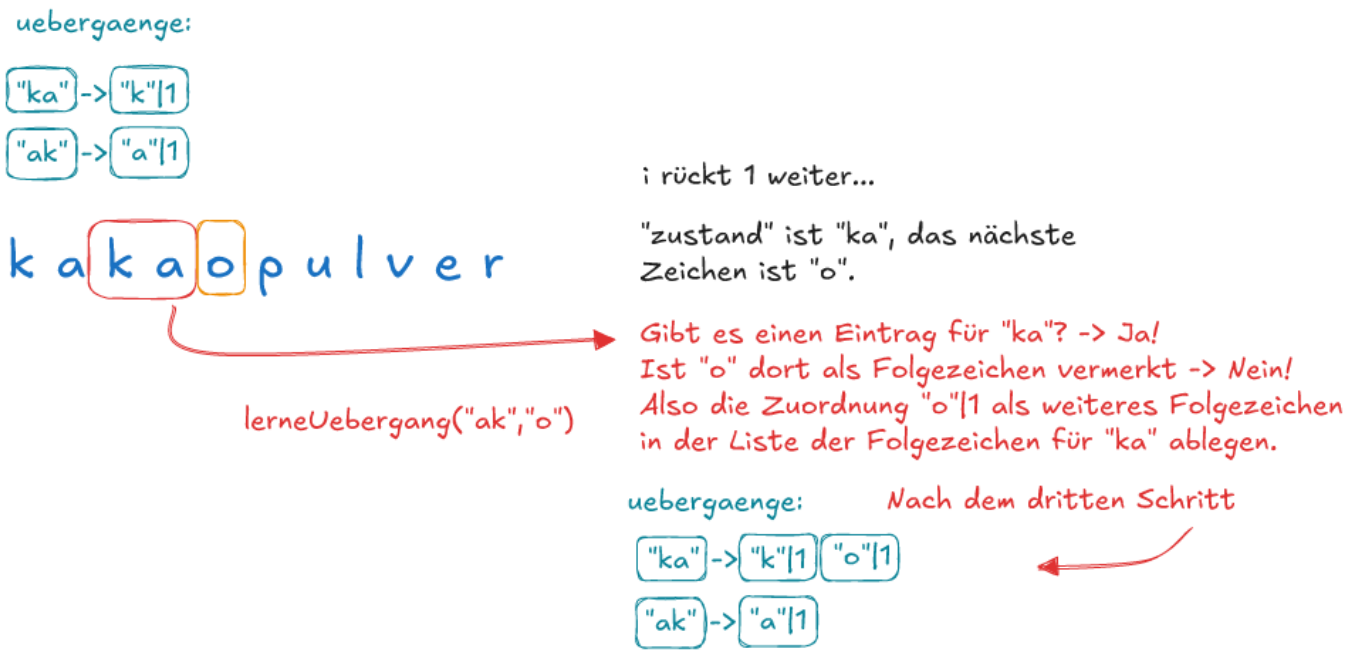

Hilfestellung: Ergebnis

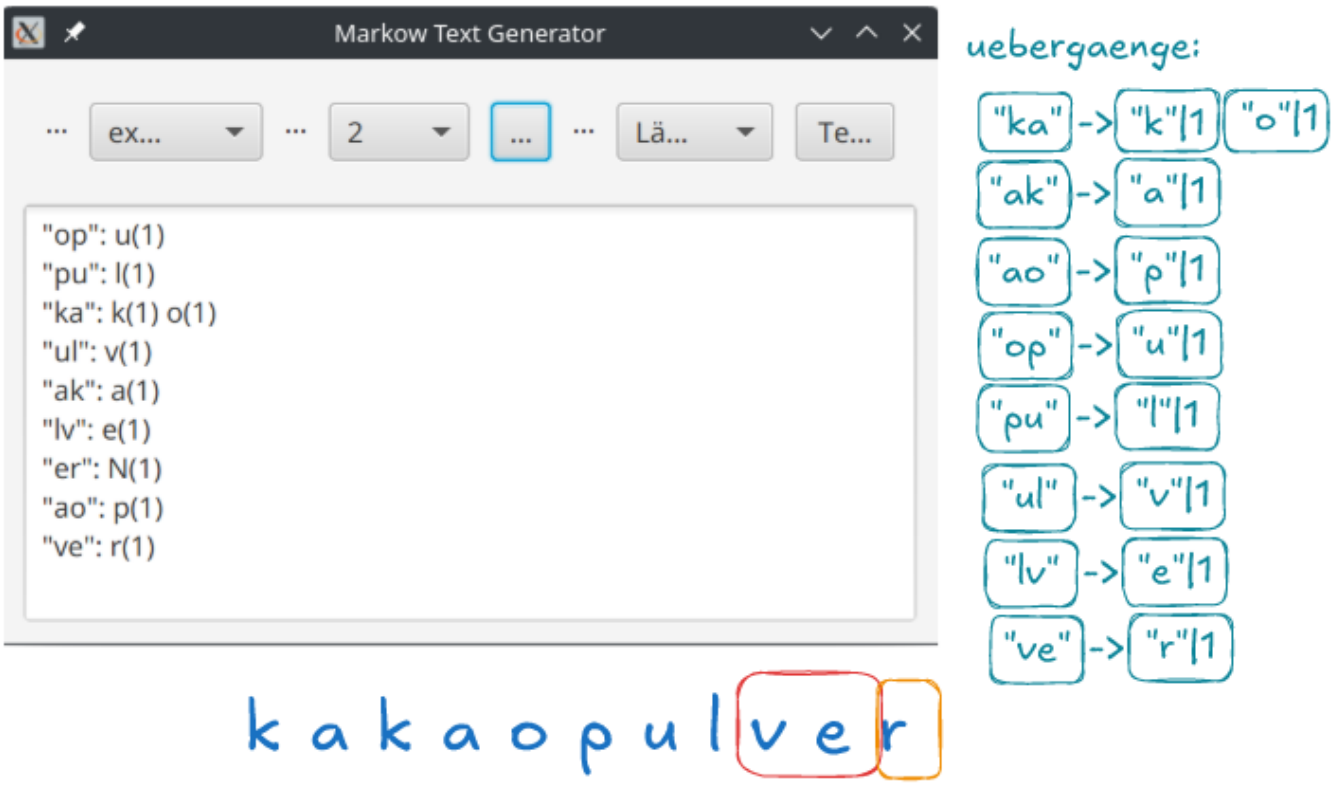

1) https://commons.wikimedia.org/wiki/File:AAMarkov.jpg

2) oder klone es

3) Die MarkowFX Klasse ist vor allem für die GUI zuständig, aber natürlich arbeiten die beiden

zusammen.

From:
https://www.info-bw.de/ -

Permanent link:
https://www.info-bw.de/faecher:informatik:oberstufe:machine_learning:mljs:markow:start?rev=1739992073

Last update: **19.02.2025 19:07**