Eckart Modrow

Programmieren mit SciSnap!

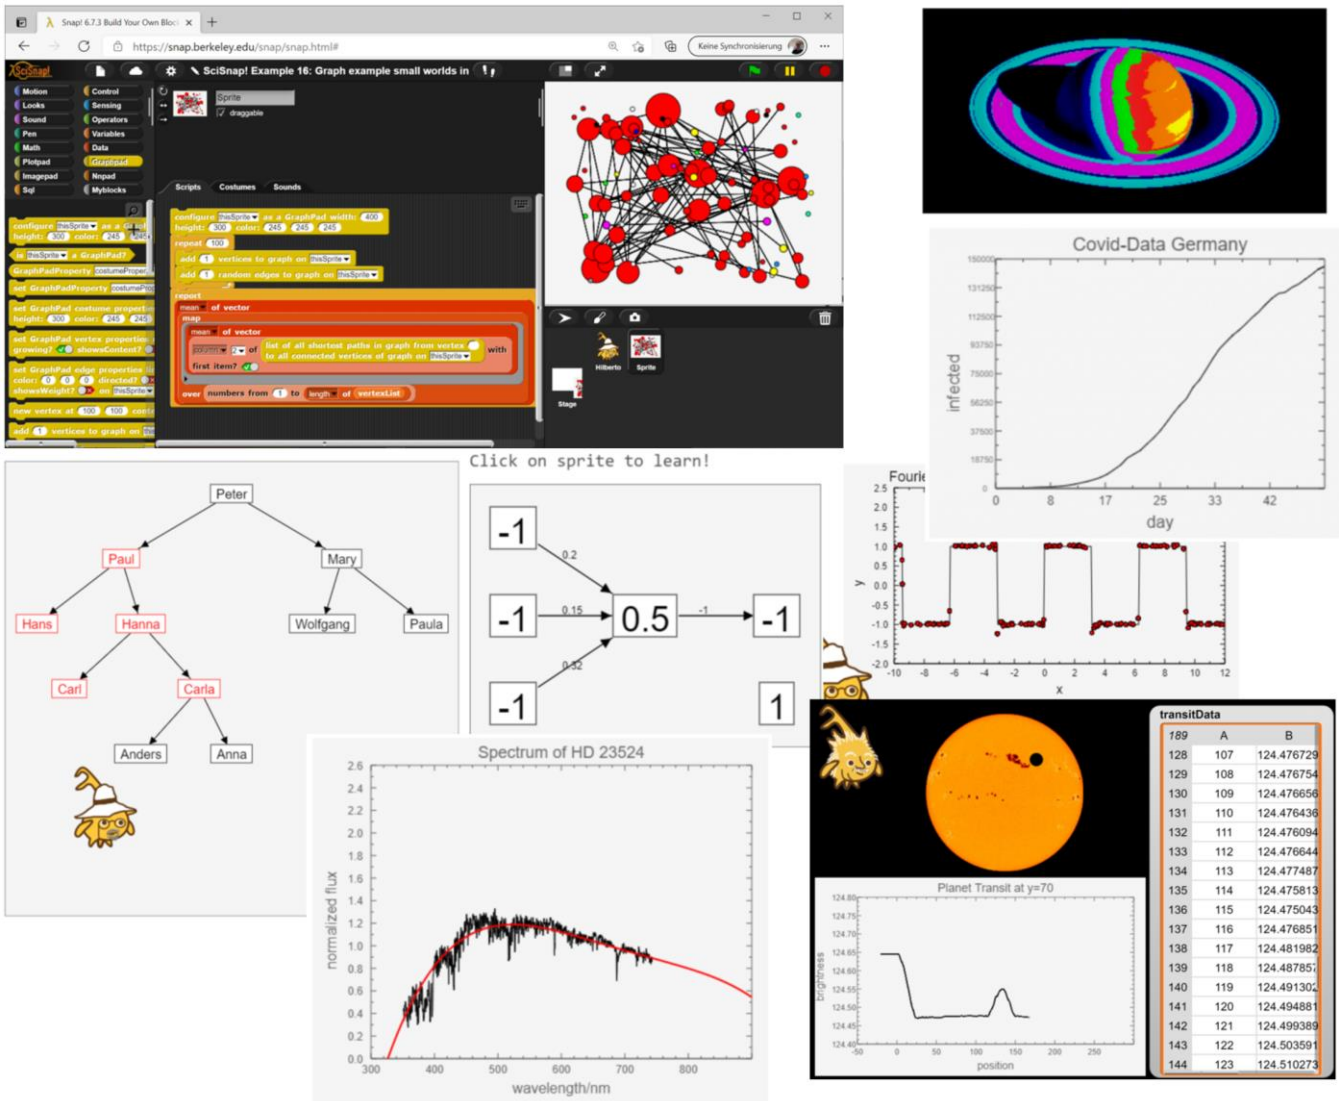

emodrow@informatik.uni-goettingen.de

Die Bibliotheken und dieses Skript können geladen werden von

http://emu-online.de/SciSnap.zip bzw.
http://emu-online.de/ProgrammierenMitSciSnap.pdf

Den SciSnap!-Starter finden Sie unter
https://snap.berkeley.edu/snap/snap.html#present:Username=emodrow&ProjectName=SciSnap!-Starter
SciSnap! selbst unter
https://snap.berkeley.edu/snap/snap.html#present:Username=emodrow&ProjectName=SciSnap!

Prof. Dr. Modrow, Eckart:
Programmieren mit *SciSnap!*

Wenn Sie mit diesem Buch zufrieden sind und ihre Anerkennung in Form einer Spende zeigen möchten, dann können Sie das auf folgendem PayPal-Konto tun:

emodrow@emu-online.de
Verwendungszweck: SciSnap!-Buch

Vorwort

Die Entwicklung von informatischen Werkzeugen, insbesondere auch auf dem Gebiet der Programmiersprachen, hat in den letzten Jahrzehnten rapide Fortschritte gemacht. Beispielsweise sind grafische Programmiersprachen entwickelt worden, die es Anfänger*innen möglich machen, sehr schnell eigenständig kleine Projekte zu bearbeiten, ohne sich um Syntaxeigenheiten usw. groß kümmern zu müssen. Steht nur eine begrenzte Zeit für das Erlernen des Programmierens zur Verfügung, dann ist das ein entscheidender Fortschritt, weil sich das Verhältnis zwischen der Einübung des Umgangs mit dem Programmierwerkzeug (der Programmierumgebung incl. -sprache) und der inhaltlichen Arbeit praktisch umdreht. Entsprechend erfolgreich werden Werkzeuge wie *Scratch*[1] vom *MIT* oder *Snap!*[2] von der *UCB* in der Schule und an Universitäten eingesetzt.

Obwohl sich bei den Werkzeugen also einiges getan hat, sieht es bei den Inhalten in Programmierkursen erstaunlich unverändert aus. Es werden einfache „Aufgaben" gestellt, die weitgehend nur dazu dienen, den Umgang mit algorithmischen Grundstrukturen und Datenstrukturen einzuüben, ohne darüber hinauszuweisen. Dazu kommen oft Arbeitstechniken, die für große Projekte mit vielen Beteiligten ihren Sinn haben, die aber von den Anfänger*innen kaum als hilfreich erfahren werden. Als Beispiel mag das Zeichnen von Nassi-Shneiderman-Diagrammen[3] (Struktogrammen) dienen, die manchmal anzufertigen sind, bevor Skripte z. B. in Scratch entwickelt werden – und das, obwohl grafische Sprachen die algorithmische Struktur durch ihre Blöcke selbst veranschaulichen. Genau dafür wurden sie ja (u. a.) entwickelt. Die Begeisterung bei den Lernenden, z. B. einige Zahlen addieren zu lassen und dazu die Mehrwertsteuer zu berechnen oder als „lustige" Einlage alle „r" in einem Text durch „l" zu ersetzen und so „chinesische" Texte zu produzieren, kann man sich vorstellen. Folgerichtig sind die „Erfolge" im Programmierunterricht auch weitgehend unverändert. Weil eigenständige Problemlösungen mit dem daraus folgenden Produktstolz ebenso selten sind wie sinnvolle Anwendungen, die Teile der Lebenswelt der Lernenden erklären, fühlen sich oft nur die Lernenden angesprochen, die sich sowieso „für Computer" interessieren. Die anderen, also die meisten, erfüllen zwar auch die Anforderungen, aber sie fragen sich zu Recht: „Was soll das?"

Der Einwand, dass man mit Anfänger*innen nun einmal nur elementare Beispiele behandeln kann, ist nicht von der Hand zu weisen. Obwohl mit den grafischen Sprachen viel mehr Zeit für das eigentliche Problemlösen zur Verfügung steht, sind die Algorithmen, die auf dieser Stufe des Lernens selbstständig entwickelt werden, ziemlich einfach. Meist handelt es sich um eine Befehlsfolge, oft innerhalb einer Schleife, die einige Alternativen nacheinander aufzählt: „Wenn dieses der Fall ist, dann tue das." Sollen solche Skripte trotzdem aussagekräftige Erfahrungen ermöglichen, dann müssen die – wenigen – verwendeten Elementarbefehle „mächtig" sein, und es ist bei den Lehrenden Fantasie gefragt, um „interessante" Probleme auf einem elementaren Niveau zu unterrichten.

---

[1] https://scratch.mit.edu/

[2] https://snap.berkeley.edu/

[3] Dieser Diagrammtyp wurde 1972 entwickelt. Zur zeitlichen Einordnung: ein Jahr später kam mit dem Intel 4004 der erste Mikroprozessor auf den Markt. Das kann für die zeitlose Bedeutung der Struktogramme sprechen, aber auch darauf hindeuten, dass nach 50 Jahren Änderungen in Erwägung gezogen werden könnten.

Das ist keine neue Erkenntnis: Zu Zeiten der Nassi-Shneiderman-Diagramme war es eine anspruchsvolle Aufgabe, auf einem technischen Gerät wie einem Bildschirm oder Drucker eine schräge Linie zeichnen zu lassen. Seit entsprechende Grafikbefehle entwickelt waren, handelte es sich um ein triviales Problem, das mit einer Anweisung erledigt wird. Noch vor wenigen Jahren war die Messwerterfassung mit Computern etwas für Spezialisten. Heute verfügt fast jede Schule über einen Satz von Sensorboards, mit denen Kinder arbeiten. Es ist eigentlich kaum zu verstehen, weshalb ausgerechnet im Bereich der Algorithmik die neuen Möglichkeiten kaum in Erscheinung treten. Es werden nach wie vor ein paar Zufallszahlen sortiert oder Worte in Großbuchstaben umgewandelt, statt mit ähnlich einfachen Skripten in Datenmengen zu „wühlen“ oder Bücher oder Bilder auf charakteristische Strukturen zu durchsuchen. Um präzise zu sein: können mit einem Befehl in einer Datenmenge charakteristische Merkmale wie Mittelwerte, Standardabweichungen, … gruppiert nach Merkmalen wie Wohnort, Geschlecht oder Beruf der Eltern ermittelt werden, dann ist im Rest des Algorithmus genügend Raum z. B. für die Suche nach Korrelationen oder die grafische Darstellung der Zusammenhänge, ebenfalls mit einem oder wenigen Befehlen. Vor allem aber lassen sich mit diesen Möglichkeiten aktuelle und offensichtlich bedeutsame Fragestellungen aufwerfen, deren Antworten die Lernenden selbst betreffen.

1. Ein Ziel von *SciSnap!* besteht deshalb darin, entsprechende Bibliotheken auf verschiedenen Gebieten wie Bildbearbeitung, Diagrammerstellung, Mathematik, Datenanalyse und Datenbanken, Graphen oder Neuronalen Netzen bereitzustellen.

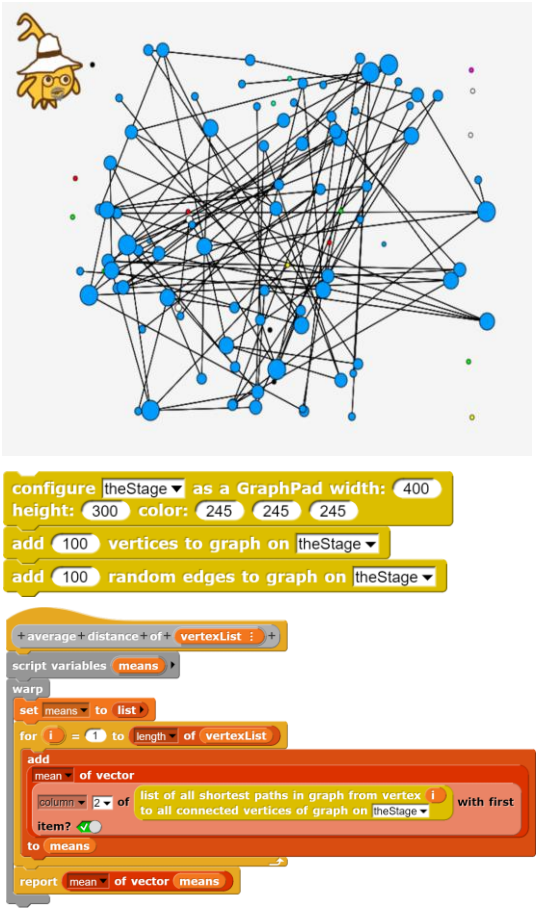

Hierzu ein (leider) aktuelles Beispiel: wirtschaftliche, geografische, soziale oder inhaltliche Beziehungen lassen sich durch Graphen darstellen. Stehen entsprechende Befehle zur Verfügung, dann erfordert die Erzeugung und Darstellung eines solchen (hier: random) Graphen in *SciSnap!* nur drei Befehle: „konfiguriere ein Sprite, *erzeuge n Knoten und danach n zufällig gewählte Kanten*“[4]. Betrachten wir die Verbindungen als Kontakte zwischen Personen, dann stellt sich die Frage, über wieviel Zwischenkontakte sich Infektionen in Pandemiezeiten ausbreiten können. Wir berechnen also die kürzesten Wege zwischen den Knoten: „*Berechne für jeden Knoten die kürzesten Wege zu allen anderen Knoten und trage diese in eine Liste ein*“. Für diese Ergebnisse berechnen wir in einer einfachen Schleife die Mittelwerte pro Knoten und daraus den Gesamtmittelwert.[5] Algorithmisch handelt es sich um ein typisches Anfängerproblem: „*durchlaufe eine einfache Schleife*“. Inhaltlich haben wir Wege zu Diskussionen über ein aktuelles gesellschaftliches Problem, über „small worlds“[6], soziale Netzwerke, Freundschaften oder Kunden-Lieferanten-Beziehungen gefunden. Der Unterricht hat an Relevanz gewonnen.

[4] Pseudocode: *configure GraphPad, add 100 vertices, add 100 edges*
[5] Pseudocode: *means=list, for i=1 to 100(add mean of row i of distances to means), mean=mean of means*
[6] https://de.wikipedia.org/wiki/Kleine-Welt-Ph%C3%A4nomen

Niemand wird alle der ziemlich umfangreichen Bibliotheken von *SciSnap!* gleichzeitig benötigen. Ordnet man auch nur eine Bibliothek den vorhandenen, schon ziemlich vollen Paletten zu, dann „laufen diese über“. Es ist also ein weiteres Ziel von *SciSnap!*, Ordnung und Übersicht in den Befehlspaletten von *Snap!* zu erhalten. Zu diesem Zweck gibt es in *SciSnap!* die Möglichkeit, Paletten (in *Snap!*: *categories*) zu erzeugen, zu löschen oder zu verstecken. In diese Paletten werden dann die benötigten Bibliotheken einsortiert.

2. Ein weiteres Ziel von *SciSnap!* ist es deshalb, die *Snap!*-Paletten zu erweitern, bei Bedarf auch zu verringern, und so *Snap!*-Versionen zu erzeugen, die für unterschiedliche Zwecke konfiguriert sind.

Verändert man *Snap!*, dann koppelt man sich von der aktuellen Entwicklung dieses fantastischen Werkzeugs ab. Ich habe deshalb darauf verzichtet, direkte Änderungen im *Snap!*-Code vorzunehmen. Stattdessen habe ich *SciSnap!* in zwei Teile geteilt: im ersten, dem *SciSnap!-Starter* wird eine Konfiguration erzeugt. Die Befehle zu deren Erzeugung werden als normales *Snap!*-Projekt abgelegt.[7] Aus dieser Konfiguration wird dann das eigentliche *SciSnap!* gestartet. Benutzt man die *Snap!*-Cloud, dann geht beides schnell.

3. Ein Ziel von *SciSnap!* ist es, mit der jeweils aktuellen *Snap!*-Version arbeiten zu können – solange es darin keine grundsätzlichen Änderungen gibt.

Es ist nicht das Ziel von *SciSnap!*, fertige Anwendungen vorzugeben. Vielmehr werden leistungsfähige Befehle bereitgestellt, mit denen sich Anwendungen erzeugen lassen. Ein Beispiel dafür sind die „Sketchpads“: Kostüme für beliebige Sprites oder die Bühne, auf denen sich schnell Skizzen erzeugen lassen. Funktionsgraphen, Bilder, Diagramme oder Histogramme lassen sich mit wenigen Befehlen erstellen, durch Skalen ergänzen – und wieder löschen, wenn es zu voll wird. Damit kann man z. B. einfach mathematische Zusammenhänge illustrieren, etwa die Wirkung von Operatoren auf komplexe Zahlen zeigen. Es wird gehofft, dass diese Beispiele die Lernenden dazu anregen, selbst andere, vielleicht bessere Anwendungen zu erzeugen, die algorithmische Methoden auf unterschiedlichen Gebieten benutzen.

4. *SciSnap!* soll sowohl als Tool wie als Entwicklungsumgebung nutzbar sein.

Snap! ist nicht nur ein fantastisches Entwicklungswerkzeug, sondern es basiert auf einem fantastischen Konzept. Als grafische Neuimplementierung der Ausbildungssprache *Scheme*[8] des *MIT*, basierend auf der „Informatikbibel“ „*Struktur und Interpretation von Computerprogrammen*“[9] von Abelson et.al., ist es konzeptionell vielen der gängigen Programmiersprachen weit überlegen. Obwohl es nicht sehr schnell ist, läuft *Snap!* schnell genug, um im Ausbildungsbetrieb flüssig eingesetzt zu werden. Seine eingebauten Visualisierungsmöglichkeiten machen es ideal für Simulationen. Die eingesetzte prototypische Vererbung macht informatische Grundkonzepte direkt erfahrbar. Trotzdem wird es, wohl wegen der Ähnlichkeit seiner Oberfläche zu *Scratch*, weitgehend unterschätzt. Ich hoffe

[7] Sie können Starter-Projekte in die Favoritenleiste aufnehmen und mit einem Klick ausführten lassen, z. B. als https://snap.berkeley.edu/snap/snap.html#present:Username=emodrow&ProjectName=SciSnap!-Starter&editMode

[8] https://en.wikipedia.org/wiki/MIT/GNU_Scheme

[9] https://mitpress.mit.edu/sites/default/files/sicp/full-text/book/book.html

deshalb, dass sich die Bereitstellung von Bibliotheken, die eher für Projekte in der Oberstufe bzw. in den ersten Semestern des Studiums bestimmt sind, positiv auf die Verbreitung in diesen Altersstufen auswirkt. Mal sehen …

5. *SciSnap!* ist für höhere Jahrgangsstufen der Schule sowie für das Grundstudium gedacht.

Das vorliegende Skript enthält eine Beschreibung der Möglichkeiten von *SciSnap!* sowie einige Beispiele, die den gedachten Einsatz erläutern. Die Bibliotheken beruhen auf den Erfahrungen zum *Maschinellen Lernen* mit *Arthur&Ina*[10] und der *Snap*!-Variante *SQL-Snap!*[11]. Sie wurden um zahlreiche mathematische Operatoren, die Sketchpads, Neuronale Netze und Graphen ergänzt. Eine ausführliche Beschreibung von *Snap!* mit vielen Beispielen findet man unter „Informatik mit Snap!“[12] – und natürlich im *Snap!*-Manual[13]. Die vorgestellten Konzepte wurden und werden im Unterricht und in Anfängervorlesungen der Universität eingesetzt.

Ach ja, und da gibt es natürlich auch zwei kleine Helfer, die Sie bei der Arbeit mit *SciSnap!* unterstützen werden. Je nach Anwendung werden sich die beiden ablösen. *Alberto*[14] wird sich um die eher naturwissenschaftlichen Anwendungen kümmern, *Hilberto*[15] um mathematische und datenorientierte. Ist der eine tätig, dann kann sich der andere etwas ausruhen. Beide behaupten, entfernte Verwandte von *Alonzo*, dem *Snap!*-Maskottchen, zu sein. Ob das stimmt? Man weiß es nicht!

Ich bedanke mich bei Jens Mönig und besonders bei Rick Hessman für seine Beiträge z. B. zum *PlotPad*, ihre Unterstützung und die zahlreichen Diskussionen und Anregungen.

Ansonsten wünsche ich viel Freude bei der Arbeit mit *SciSnap!*.

Göttingen, am 1.7.2021

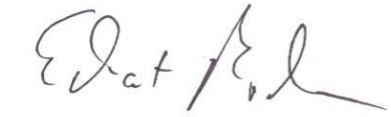

[10] ebenso wie andere Materialien auf http://emu-online.de
[11] http://snapextensions.uni-goettingen.de/
[12] http://ddi-mod.uni-goettingen.de/InformatikMitSnap.pdf
[13] https://snap.berkeley.edu/snap/help/SnapManual.pdf
[14] er arbeitet in der Astrophysik bei Rick Hessman
[15] https://de.wikipedia.org/wiki/David_Hilbert

Inhalt

1 SciSnap!-Starter

1.1 Startkonfigurationen erzeugen[16]

Solange *Snap!* selbst noch nicht mit änderbaren Paletten-Konfigurationen arbeitet, muss man sich mit selbstgestrickten Lösungen behelfen – wenn man so etwas haben will[17]. Da ich zusätzlich mit der aktuellen *Snap!*-Version arbeiten möchte, verbieten sich ernstere Eingriffe in den eigentlichen Code. *Snap!* sieht sich beim Laden eines Projekts an, in welche Palette die neuen Blocks einzusortieren sind. Fehlt diese Palette, dann werden die Blöcke ignoriert. Wir müssen deshalb zur Erzeugung von *SciSnap!*-Anwendungen in zwei Schritten arbeiten:

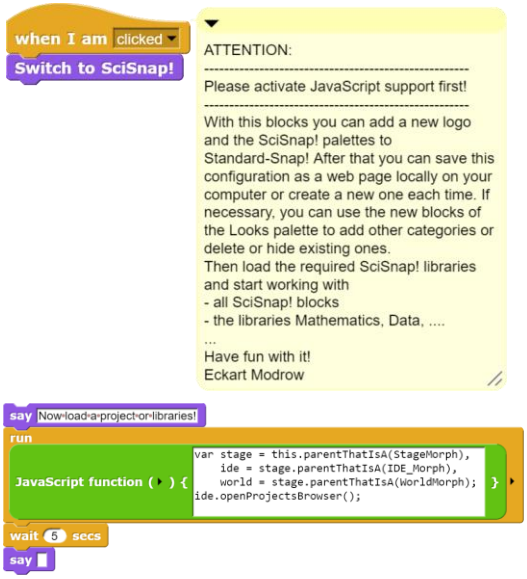

1. Neue Paletten und einige globale Variable, mit denen *SciSnap!* arbeitet, werden erzeugt. Nicht benötigte Paletten können versteckt werden. Wenn man möchte, können danach gleich die benötigten Bibliotheken in die entsprechenden Paletten geladen werden. Sie sollten einen „Grüne-Flagge-Block“ einfügen, an den die Startbefehle gehängt werden. Diese Starter-Konfiguration wird als *Snap!*-Projekt z. B. in der Cloud gespeichert.
2. Sie sollten einen Link zu „Ihrem“ *SciSnap!*-Starter-Projekt in die Favoritenleiste aufnehmen in einer Form, die die „Grüne-Flagge-Befehle“ sofort ausführt: z. B. als
   http://snap.berkeley.edu/snap/snap.html#present:Username=emodrow&ProjectName=SciSnap!-Starter&editMode
   Wenn Sie den nebenstehenden JavaScript-Block Ihrem Skript hinzufügen, folgt sofort der normale „Projekt-öffnen“-Dialog.
3. In dieser Konfiguration wird gearbeitet und das aktuelle Projekt wird wiederum in der Cloud gespeichert.
4. Will man später am aktuellen Projekt weiterarbeiten, dann lädt das Starter-Projekt und mit diesem die aktuelle *Snap!*-Version z. B. mit dem Link in der Favoriten-Leiste. Nach dessen Ausführung geht es weiter wie immer. Liegen beide Dateien in der Cloud, dann ist der Prozess einfach und schnell durchzuführen.
5. Will man ein neues Projekt mit „New“ aus dem File-Menü beginnen, dann bleiben die Paletten erhalten, aber die *SciSnap!*-Blöcke müssen neu geladen werden.

[16] Durch die aktuellen Probleme mit JavaScript muss derzeit zuerst JavaScript im Werkzeugmenü freigeschaltet werden.

[17] Um es klar zu sagen: mithilfe des *import library*-Blocks können Sie die *SciSnap!*-Bibliotheken auch in jede andere Palette laden. Sie müssen also keine neuen Paletten erzeugen!

Wir gehen das anhand eines Beispiels durch:
Ziel ist es, mit den SQL-Blöcken zu arbeiten und zusätzlich eine Palette für eigene Blöcke einzufügen. Nicht benutzt werden sollen die Paletten für *Sound* und den *Pen*.

1. Schritt: Wir laden *Snap!* und danach die allgemeine *SciSnap!-Starter*-Datei. (Wir könnten stattdessen auch die *SciSnap! GlobalBlocks* -Bibliothek importieren.) Wir erhalten den nebenstehenden Bildschirm. Dort schalten wir ggf. JavaScript frei.

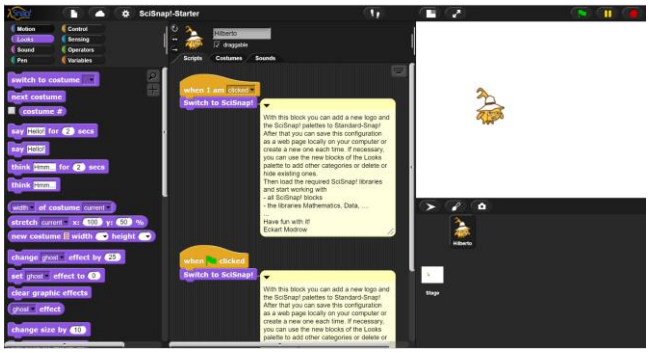

2. Schritt: Wir geben an, welche Paletten zu verstecken sind (hier: *Sound* und *Pen*) und welche unter welchen Namen und Farben erzeugt werden sollen (hier: *Sql* und *MyBlocks*). In diesem Fall soll die SQL-Bibliothek auch gleich in die Palette „Sql“ geladen werden. Dieses Projekt wird zuerst unter dem Namen „*SciSnap!-SQLStarter*“ gespeichert.

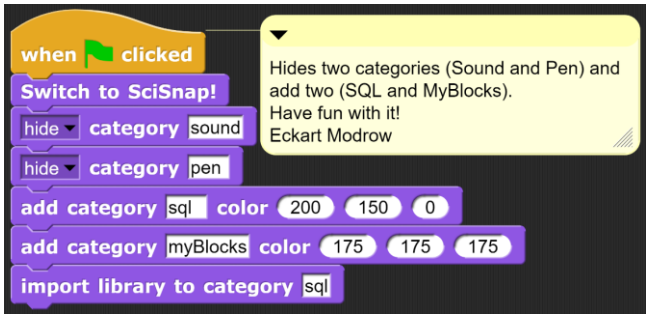

3. Schritt: Wir speichern den folgenden Link als Favoriten: (ohne Leerzeichen und Zeilenvorschübe): http://snap.berkeley.edu/snap/snap.html#present:Username=emodrow&ProjectName=SciSnap!-SQLStarter&editMode
Danach wird es ausgeführt.

Als Ergebnis erhalten wir eine SQL-Arbeitsumgebung.

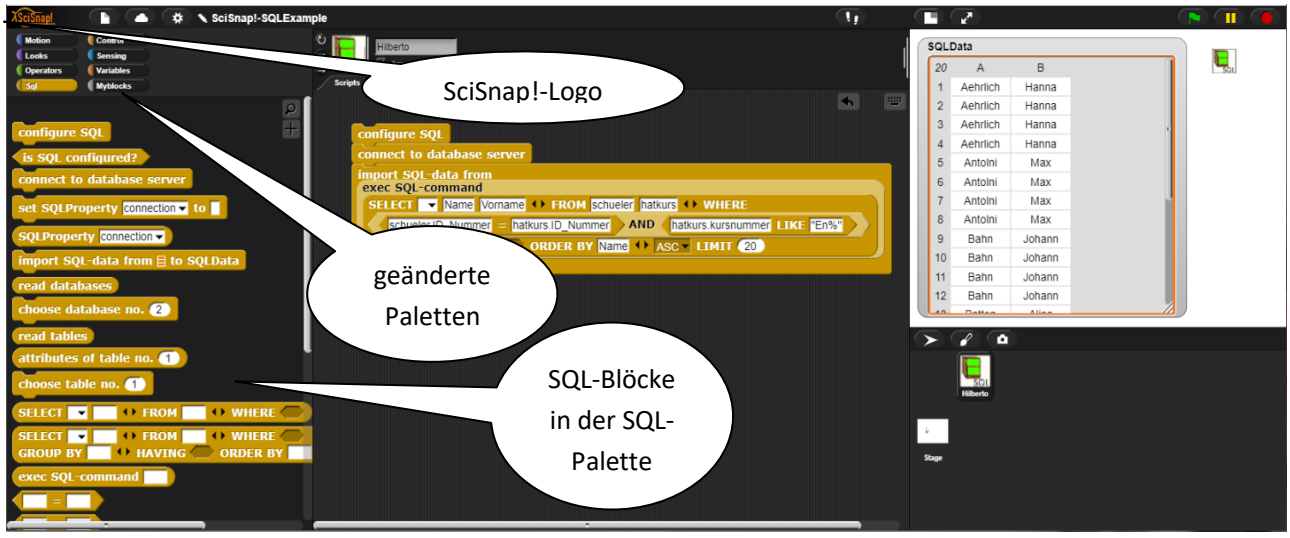

1.2 Neue Blöcke in den Standardpaletten von *Snap!*

Die zusätzlichen Blöcke der *Looks*-Palette befinden sich dort, weil sie einer Standard-Palette von *Snap!* zugeordnet werden müssen, um geladen zu werden. In die *Looks*-Palette passen sie am besten und stören am wenigsten. Es handelt sich um die folgenden Blöcke:

	Erzeugt das *SciSnap!*-Logo und zeigt es an, erzeugt die gewünschten Paletten. Vergrößert die Bühne auf 800x600 Pixel.
	Liest eine Eigenschaft.
	Erlaubt das Verändern oder Erzeugen einer Eigenschaft.
	Erzeugt drei globale *SciSnap!*-Variable *„SciSnap!Properties“*, *„SciSnap!Data“* und *„SciSnap!Messages“*. Setzt einige Eigenschaften.
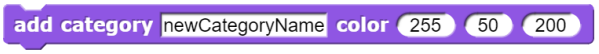	Fügt eine Palette mit dem genannten Namen und den RGB-Farben ein.
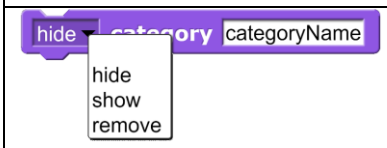	Versteckt, zeigt oder löscht eine Palette. Die Standard-Paletten von *Snap!* werden nicht gelöscht.
	Importiert eine Bibliothek beliebigen Namens in die angegebene Palette. Die Bibliothek wird mit der Maus ausgewählt.
	Ändert den Namen des aktuellen Sprites.
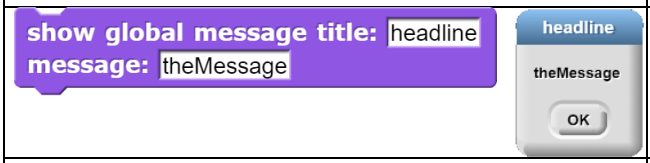	Erzeugt ein Meldungsfenster in der Mitte des Bildschirms.
	Gibt einen Fehler, wenn möglich, über das aktuelle Sprite aus und trägt ihn in *SciSnap!Messages* ein.
	Liefert eine Kopie des aktuellen Kostüms.
	Liefert das Kostüm eines Sprites, z. B. für Pooling-Operationen.

Zusätzlich finden sich in der *Control*-Palette die folgenden Blöcke zum Umgang mit Sprites:

	Erzeugt ein Duplikat des angegebenen Sprites mit dem angegebenen Namen.
	Erzeugt einen permanenten Klon des angegebenen Sprites mit dem angegebenen Namen.
	Importiert ein lokal gespeichertes Sprite.

Die *Operatoren*-Palette enthält zusätzliche mathematische und String-Operatoren.

random	Liefert eine Zufallszahl zwischen 0 und 1.
π	Liefert π.
e	Liefert die Eulersche Zahl e.
round 1.2357 to 2 digits	Liefert die angegebene Zahl gerundet auf die angegebene Zahl von Nachkommastellen.
5 !	Liefert n!
(5) (3)	Liefert den Binomialkoeffizienten.
is a vector number text vector transposed-vector matrix table complex-number complex-number-Cartesian-style complex-number-polar-style predicate set	Einige Typ-Prüfungen.
substring of thisString from 1 to 4	Liefert eine Teil-Zeichenkette.
delete all this in thisString all first	Löscht alle oder die erste Zeichenfolge(n) in einer Zeichenkette.
upper case thisString	Liefert einen String in Großbuchstaben.
lower case ThisString	Liefert einen String in Kleinbuchstaben.
write text this text to TXT-file this file	Schreibt eine Zeichenkette in eine Textdatei im Download-Ordner des Browsers.
index of ring in thisString	Liefert die Position einer Teilzeichenkette.
replace all this with that in thisString all first	Ersetzt alle oder die erste Zeichenfolge(n) in einer Zeichenkette.
get label from text-data SciSnap!Data at column 1 max. textwidth 5 column spacing 2	Liest eine Spaltenüberschrift aus einer Tabelle, z. B. zur Diagrammbeschriftung.
datetime: → seconds today Julian Date decimal years days this year hours this year minutes this year seconds this year hours today minutes today seconds today	Umrechnungen von *datetime* in die angegebenen Werte.
Zusätzlich findet man in der Variablen-Palette die folgenden Variablen und in der Sensing-Palette einen Block für standardisierte Zeitangaben: Weitere Variable werden je nach Verwendung der Bibliotheken bei der Konfiguration der Sprites angelegt.	SciSnap!Data SciSnap!Messages SciSnap!Properties datetime 2021-07-02T10:08:14

2 Die Struktur der SciSnap!-Sprites

Der zweite Teil von *SciSnap!* besteht aus voneinander unabhängigen Bibliotheken, die einerseits generell in *Snap!*-Skripten einsetzbar sind (*Math*, *Data*, *SQL*), andererseits mit besonders konfigurierten Sprites arbeiten (*NeuralNet*, *Graph*, *PlotPad*, *ImagePad*). Der Grund dafür besteht in den Properties, die für ein *NeuronalNet* nun einmal sehr anders sind als für ein *PlotPad*. Zusätzlich müssen solche „Spezial-Sprites" über eigene Datenbereiche verfügen, in denen z. B. Bilddaten gespeichert sein können. Ein globaler Datenbereich findet sich in der Variablen *SciSnap!Data*, mit der z. B. die Blöcke der *Data*-Bibliothek im Default-Fall arbeiten. Für die Erstellung von z. B. Diagrammen ist es dagegen sinnvoller, dass ein *PlotPad* einen eigenen Datenbereich besitzt, der unabhängig von z. B. dem des *ImagePads* ist, auf das sich die Diagramme beziehen.

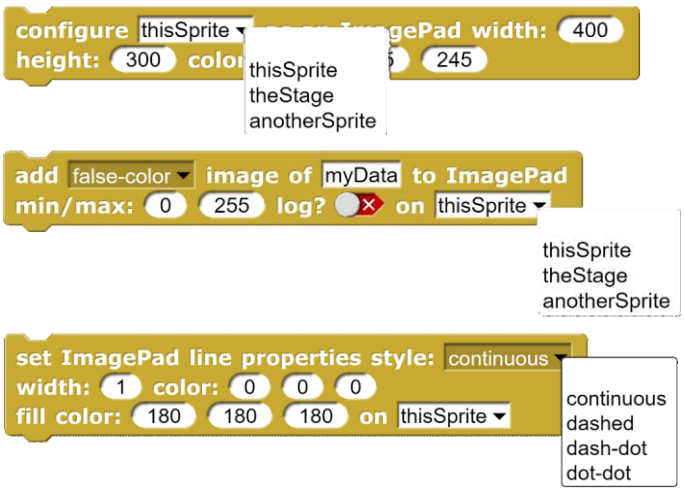

Jedes Sprite und auch die Bühne lassen sich als „Spezial Sprites" konfigurieren, z. B. als *ImagePad*. Dabei werden die lokalen Variablen *myProperties* und *myData* erzeugt und einige sinnvolle Voreinstellungen bei den Eigenschaften vorgenommen. Die Properties sind meist zu Gruppen, z. B. über Kostümeigenschaften (*costumeProperties*) oder die Art, Linien zu zeichnen (*lineProperties*), zusammengefasst. Alle Blöcke, die eine bestimmte Konfiguration erfordern, fragen anfangs die Eigenschaft *typeOfConfiguration* des Sprites, mit dem sie arbeiten sollen, ab. Stimmt diese nicht, erfolgt eine Fehlermeldung. Die Gruppen von Eigenschaften können mit den entsprechenden Blöcken geändert werden.

Der Aufbau der *SciSnap!Sprites* orientiert sich also an der Idee von dokumentierten Datensätzen, die aus zwei Teilen bestehen: den *Metadaten*, die die Struktur und den inhaltlichen Kontext der Daten beschreiben (z. B. Zahlenformat, Bilddimensionen, Aufnahmegerät, Aufnahmedatum, ...) und den dazugehörigen reinen *Datensegmenten*. Metadaten bestehen gewöhnlich aus *Dictionaries* - Namen mit zugewiesenen Werten (z. B. "Aufnahmedatum: 24.12.2018"). Beispiele für diese Struktur sind FITS-Dateien [FITS], die in der Astrophysik Standard sind, aber auch in der Vatikanischen Bibliothek Verwendung finden, oder JPEG Bilder vom Handy. Auch hier gibt es Metadaten (Bildgröße, Kompressionsgrad, Aufnahmedatum, …), ohne die eine Bilderzeugung nicht möglich wäre.

Wir adaptieren diese Struktur, indem wir einem *SciSnap!Sprite* zwei lokale Variable verpassen, die jeweils die Daten (*myData*) und die Datenbeschreibung (*myProperties*) enthalten. Diese Variablen können einerseits durch den Import von Daten aus unterschiedlichen Quellen (SQL-Abfrage, Textdatei, CVS-Datei, JSON-Datei, FITS-Datei, direkte Zuweisung, …) gefüllt werden, wobei die Eigenschaften *myProperties* den jeweiligen Daten anzupassen sind. Andererseits kann das auch „per Hand" geschehen. Mithilfe dieser Eigenschaften können Daten in grafische Darstellungen (Graph, Datenplot, Histogramm, Bild, …) umgesetzt werden, wobei als Quelle entweder *myData* oder eine andere geeignete Tabelle gewählt wird.

Wichtig ist, dass die Bilderzeugung die Originaldaten nicht verändert. Wird also z. B. eine Aufnahme des Jupiters benutzt, um die Abstände seiner Monde zu bestimmen, dann müssen diese zumindest im Bild sichtbar sein. Dafür kann nach dem Einstellen einiger Parameter z. B. ein Falschfarbenbild erzeugt werden. In diesem wird der Jupiter selbst ziemlich unstrukturiert erscheinen. Will man dagegen das „Auge“ des Planeten genauer untersuchen, dann müssen die Parameter ganz anders gewählt werden, sodass die Monde wiederum kaum zu sehen sind. Alle diese Änderungen müssen in den Pixeln des aktuellen Kostüms des *Snap!*-Sprites geschehen, ohne die Bilddaten selbst zu beeinflussen.

Weil Tabellen in *Snap!* sehr schön dargestellt werden können, ist diese Darstellungsform nicht zusätzlich implementiert. Dafür ist der Datentyp *table* mit zahlreichen der im Bereich von *Data Science* üblichen Operationen (Tabellenoperationen, Korrelationsberechnung, affine Transformationen, Lösen linearer Gleichungssysteme, …) implementiert, der ausreichend schnell auch mit größeren Datenmengen umgehen kann.

Da *SciSnap!* (derzeit) etwa 250 neue Blöcke enthält, wurden diese nach ihrer Funktionalität gruppiert und auf verschiedene Bibliotheken und Sprite-Konfigurationen verteilt: mehrere *Math*-Bibliotheken für unterschiedliche Gebiete der Mathematik (60 Blöcke), eine *Data*-Bibliothek (30 Blöcke) zum Umgang mit den eigentlichen Daten, ein *ImagePad* zur Bildbearbeitung (19 Blöcke), ein *PlotPad* für grafische Darstellungen (24 Blöcke), ein *Neural-NetPad* für Perceptron-Netze, eine *SQL*-Bibliothek für Datenbankanfragen (27 Blöcke) und ein *GraphPad* für Anwendungen der Graphentheorie. Hinzu kommen die schon genannten Blöcke in den Standardpaletten von *Snap!*. Alle Blöcke sind global und enthalten das Ziel der Operation (*thisSprite*, *theStage* oder den Namen eines anderen Sprites). Objektorientierte Aufrufe sind deshalb weitgehend unnötig.

Die konfigurierten Sprites haben die folgende Struktur:

Sie importieren mithilfe der Bibliotheken Daten aus …

- Bild-Dateien
- Text-Dateien
- SQL-Abfragen
- JSON-Dateien
- CSV-Dateien
- …

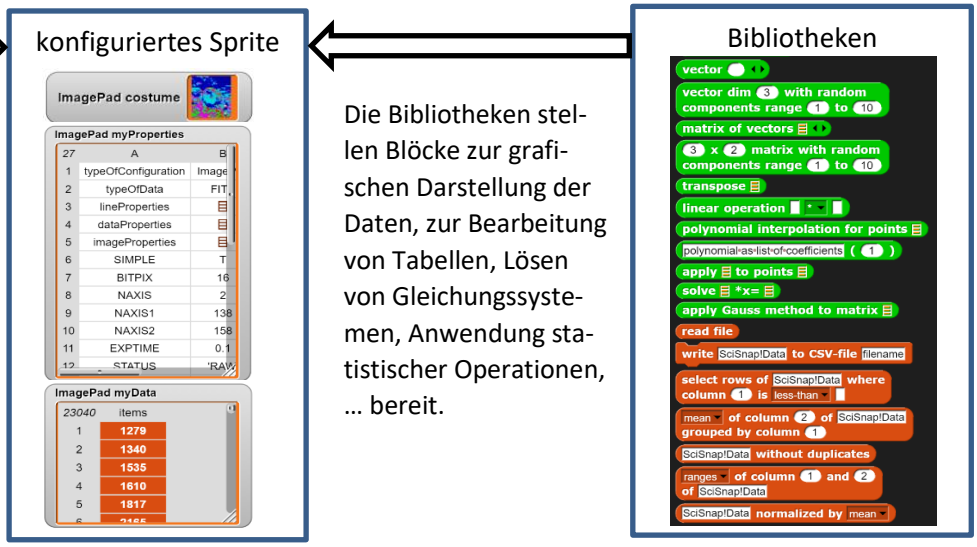

Die Bibliotheken stellen Blöcke zur grafischen Darstellung der Daten, zur Bearbeitung von Tabellen, Lösen von Gleichungssystemen, Anwendung statistischer Operationen, … bereit.

Die meisten Blöcke erhalten ihre Parameter (Bildgröße, Wertebereiche, Farben, …) aus dem Dictionary *myProperties*. Die voreingestellten Eigenschaften ermöglichen es, ohne allzu viele Parameter Blöcke zum Erstellen von Grafiken, Diagrammen, … zu benutzen. Passen die Werte nicht, dann werden die Eigenschaften entweder einzeln oder in Gruppen geändert.

3 Die SciSnap!-Bibliotheken

Im Folgenden werden die Bibliotheken tabellarisch vorgestellt. Umfangreichere Beispiele, die meist mehrere Bibliotheken nutzen, folgen danach.

Die *SciSnap!*-Bibliotheken wurden – wie alle Block-Bibliotheken von *Snap!* – Paletten zugeordnet und gespeichert. Zum Laden ist es Voraussetzung, dass diese Paletten vorhanden sind. Soll eine Bibliothek in eine andere Palette geladen werden, dann kann dafür der Block 

benutzt werden. Mit dessen Hilfe können die Bibliotheken auch in einer „normalen“, also nicht modifizierten *Snap!*-Version genutzt werden.

3.1 Die Mathematik-Bibliotheken (SciSnap!FullMathLibrary.xml)

3.1.1 Komplexe Zahlen (SciSnap!ComplexNumbersLibrary.xml)

Falls Sie umfangreichere Operationen mit komplexen Zahlen planen, sollten Sie sich überlegen, die *Scheme*-Bibliothek von *Snap!* zu benutzen (*Bignums*-library). *SciSnap!* ist eher für komplexe Arithmetik sowie die Veranschaulichung der Operationen gedacht. In *SciSnap!* werden komplexe Zahlen als 3-elementige Listen dargestellt, wobei der erste Eintrag das Format der Zahl bezeichnet: entweder den „kartesischen“ Stil $z = a + b \cdot i$ oder die Polarform $z = r \cdot e^{i\varphi}$. Für diese beiden Formen gibt es Eingabeblöcke:

	Liefert eine komplexe Zahl in kartesischer Form.
	Liefert eine komplexe Zahl in Polarform.

Bei Bedarf können diese Darstellungsformen ineinander umgewandelt werden, und man kann arithmetische Operationen durchführen.

	Liefert eine komplexe Zahl in kartesischer Form.
	Liefert eine komplexe Zahl in Polarform.
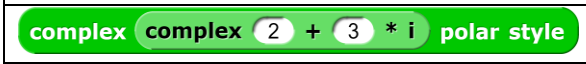	Beispiel für eine Formatumwandlung.
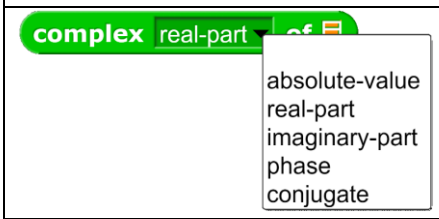	Auf die Komponenten einer komplexen Zahl kann – unabhängig von ihrem Format – zugegriffen werden.
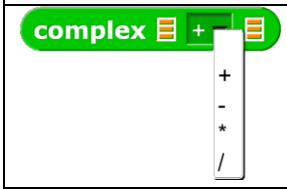	Und man kann natürlich mit ihnen rechnen.

Beispiel für eine Multiplikation: 

3.1.2 Das MathPad (SciSnap!MathPadLibrary.xml)

configure sprite thisSprite as a MathPad width: 400 height: 300 color: 245 245 245	Konfiguriert ein Sprite als MathPad und zeichnet ein 3-dimensionales Koordinatensystem zentriert in der Mitte.
is thisSprite a MathPad?	Test auf MathPad-Konfiguration.
set MathPadProperty costumeProperties of thisSprite to	Setzt eine MathPad-Eigenschaft.
MathPadProperty costumeProperties of thisSprite	Liest eine MathPad-Eigenschaft.
set MathPad costume properties width: 400 height: 300 color: 245 245 245 offsets: 0 0 on thisSprite	Setzt die Kostüm-Eigenschaften eines MathPads auf die angegebenen Werte.
set MathPad properties lineWidth: 1 onlyPoints? dimension: 3 maxValue: 10 startPoint: 0 0 0 on thisSprite	Setzt die Linien-Eigenschaften eines MathPads auf die angegebenen Werte. Ist „onlyPoints“ gesetzt, werden nur die Endpunkte gezeichnet.
add centered axes to a MathPad on thisSprite	Zeichnet das Koordinatensystem auf ein MathPad.
plot vector color: 255 0 0 on MathPad ange startpoint? vector complex-number line-to object-of	Zeichnet einen Vektor, eine komplexe Zahl, eine Linie oder ein Objekt, das durch eine Liste von Vektoren beschrieben wird.
affine transformation of by --> for MathPad	Führt eine affine Transformation in der Ebene für eine Punktliste, z. B. ein Bild, aus, die durch die Zuordnung von drei Punkten zu drei anderen beschrieben ist.

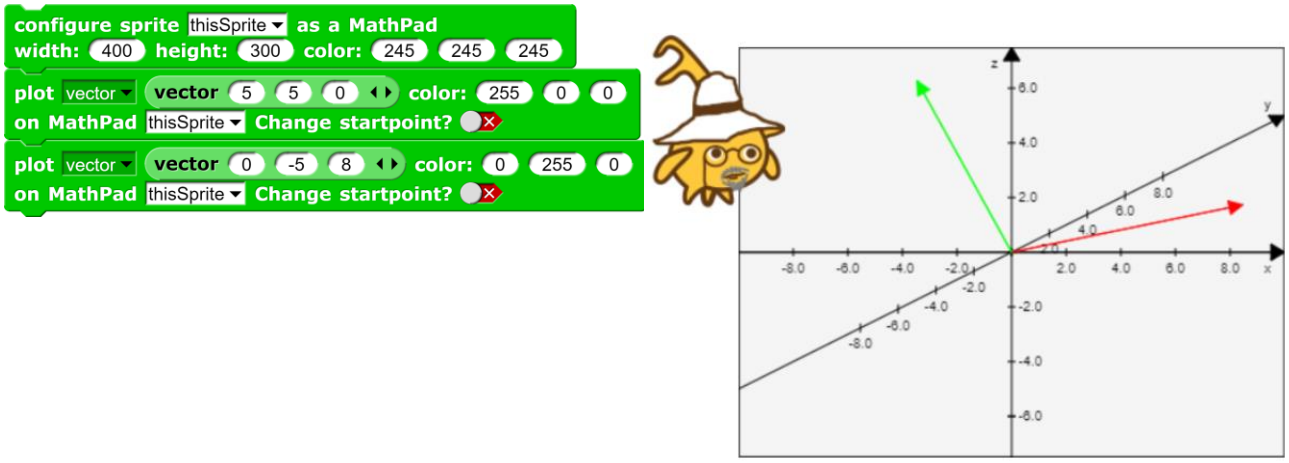

3.1.3 **Lineare Algebra** (SciSnap!LinearAlgebraLibrary.xml)

SciSnap! kennt Vektoren und Matrizen sowie die gängigen Operationen mit ihnen. Beide werden als Listen bzw. Listen von Listen dargestellt, und beide können in transponierter Form vorliegen. Sie werden mit den folgenden Blöcken erzeugt:

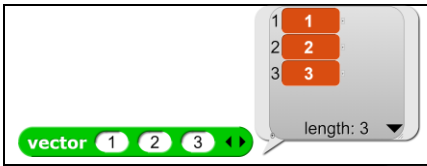	Liefert einen Vektor beliebiger Dimension mit vorgegebenen Werten.
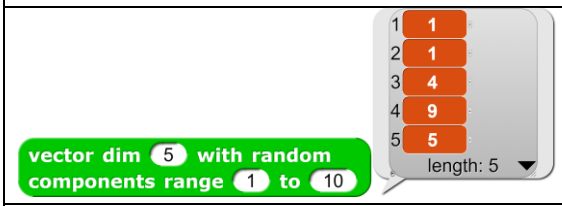	Liefert einen Vektor beliebiger Dimension mit Zufallswerten aus dem angegebenen Bereich.
	Liefert die Matrix aus den angegebenen Vektoren.
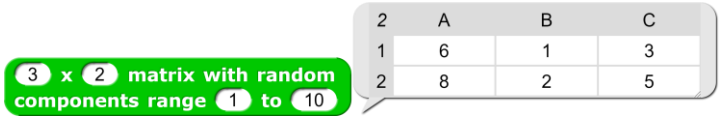	Liefert eine Matrix beliebiger Dimension mit Zufallswerten aus dem angegebenen Bereich.
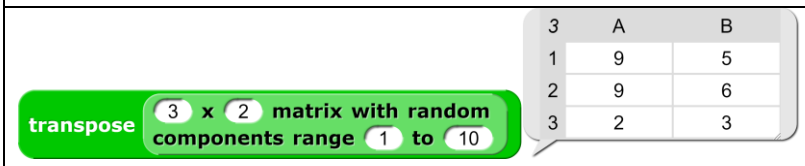	Matrizen und Vektoren können transponiert werden.
 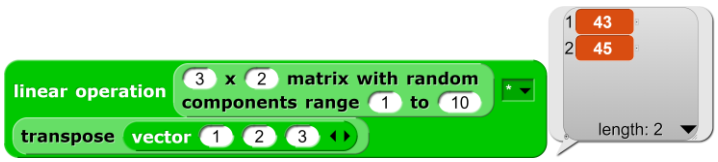	Zwischen Skalaren, Vektoren und Matrizen können die jeweils zugelassenen Operationen ausgeführt werden. Da Vektoren mit den arithmetischen Standard-Operatoren von *Snap!* bearbeitet werden können, gibt es dafür keine gesonderten Blöcke.
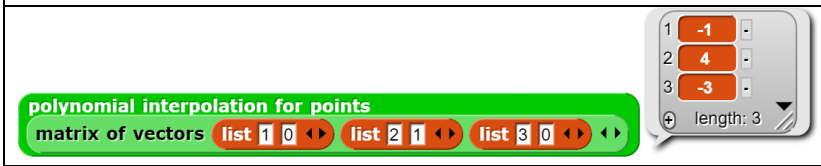	Berechnet die Koeffizienten des Polynoms durch n Punkte.
	Und für solche Polynome kann man dann Funktionswerte berechnen.
	Wendet eine Matrix auf eine Punktliste an (s. Beispiel).

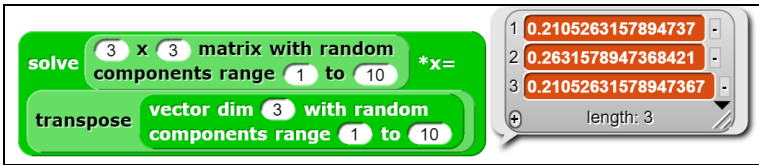	Berechnet die Lösung eines linearen Gleichungssystems.
	Der Block liefert mehrere Daten über die übergebene Matrix: die ggf. diagonalisierte Matrix, deren Rang, ob Spaltenvertauschungen stattgefunden haben und die jetzige Reihenfolge der Spalten.
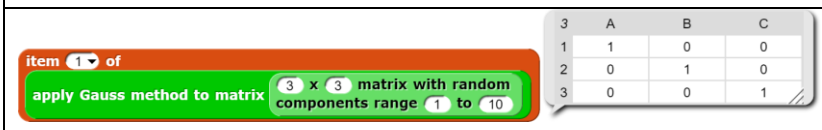	Interessiert nur die diagonalisierte Matrix, dann betrachten wir das erste Element des Resultats.

Beispiele:

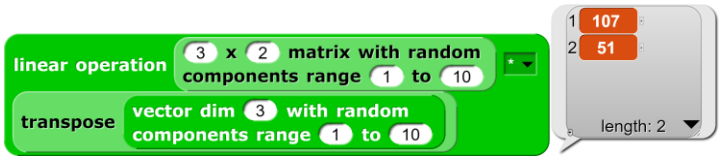

3.1.3 **Statistik** (SciSnap!StatisticsLibrary.xml)

Für statistische Anwendungen enthält *SciSnap!* eine Reihe von Verteilungen. Korrelationsberechnung, Varianzen etc. sind in der Datenbibliothek implementiert, Binomialkoeffizienten und Fakultäten findet man in der Operatoren-Palette.

	Wahrscheinlichkeiten der Binomialverteilung $b(N,p,k) = \binom{N}{k} \cdot p^k \cdot (1-p)^{N-k}$
	Berechnet die kumulierte Verteilungsfunktion der Binomialverteilung.
	Wahrscheinlichkeiten der hypergeometrischen Verteilung $h(N,M,n,k) = \frac{\binom{M}{k} \cdot \binom{N-M}{n-k}}{\binom{N}{n}}$
	Berechnet die kumulierte Verteilungsfunktion der hypergeometrischen Verteilung.
	Wahrscheinlichkeiten der Poisson-Verteilung $p(\theta,k) = \frac{\theta^k \cdot e^{-\theta}}{k!}$
	Berechnet die kumulierte Verteilungsfunktion der Poisson- Verteilung.
	Wahrscheinlichkeiten der Pareto-Verteilung $pareto(x_{min},k,x) = \frac{k \cdot {x_{min}}^k}{x^{k+1}};$ $x \geq x_{min}; 0\ sonst$
	Wahrscheinlichkeiten der Normalverteilung $n(x,\mu,\sigma) = \frac{e^{-\frac{(x-\mu)^2}{2\sigma^2}}}{\sqrt{2\pi\sigma^2}};$

3.1.4 **Mengen** (SciSnap!SetLibrary.xml)

Mengen sind in *SciSnap!* als dreielementige Listen implementiert. Es gibt zwei Versionen davon. In der ersten werden Prädikate (x<5) verwendet, um neben einer Aufzählung der Elemente Bereiche einzugeben. In der zweiten geschieht das über Intervalle (3<x<7). Die Bibliotheken unterscheiden sich nur bei der Definition einer Menge und einem zusätzlichen Block für Intervallkomprimierung. Im ersten Element einer Menge steht der Typ („set“), im zweiten entweder ein Prädikat oder es ist leer bzw. eine Liste von Intervallen. Im dritten Element steht eine Liste mit den Elementen, die durch das Prädikat oder die Intervalle noch nicht erfasst sind. Zusammengesetzte Prädikate sind wiederum Listen, die im ersten Element den booleschen Operator („NOT“, „OR“, „AND“) und danach ein oder zwei Prädikate enthalten, die wiederum zusammengesetzt sein können. Mengen dieses Typs können entweder durch Aufzählung oder durch Angabe eines Prädikats erzeugt werden.

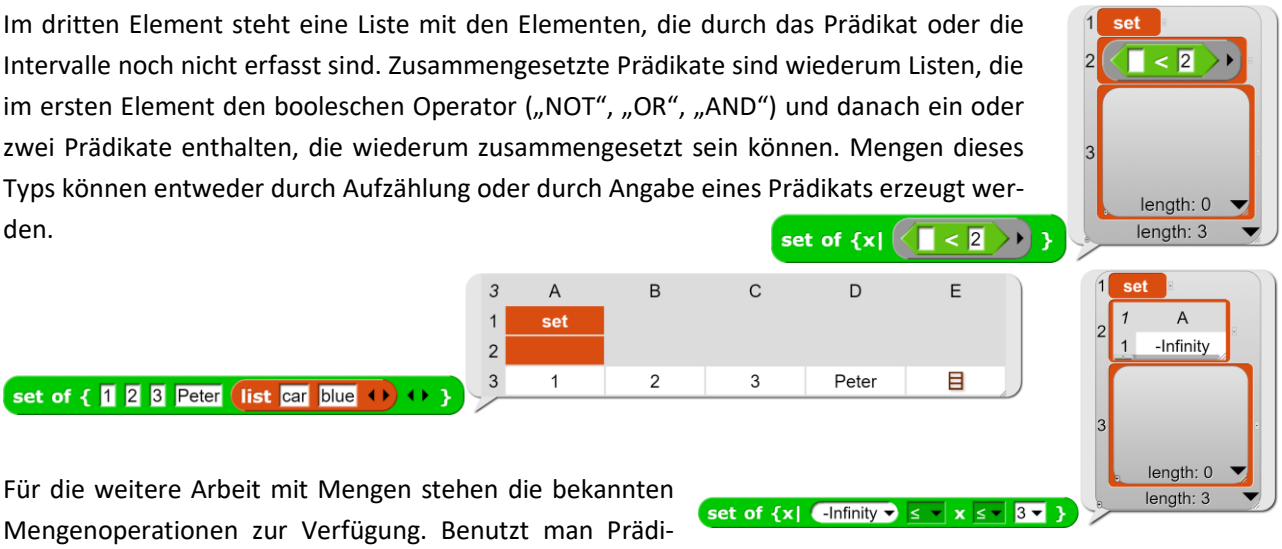

Für die weitere Arbeit mit Mengen stehen die bekannten Mengenoperationen zur Verfügung. Benutzt man Prädikate, dann sind als Elemente weitgehend nur Zahlen und Zeichenketten sinnvoll. Die folgenden Operationen beziehen sich in diesem Fall nicht auf beschränkte Mengen. Prädikate bzw. Intervallzugehörigkeiten können mit *„evaluate with“* evaluiert werden.

evaluate ▤ with ☐ evaluate ringified predicate with ☐	Liefert das Ergebnis des Prädikats, angewandt auf das übergebene Element bzw. einer Intervall-Liste.
element ε set ?	Liefert „wahr“, falls das Element ein Element der Menge ist, sonst „falsch“.
set1 ∩ set2	Liefert die Schnittmenge zweier Mengen.
set1 ∪ set2	Liefert die Vereinigungsmenge zweier Mengen.
element set ⇨ text {2,3,Peter,[car,blue],0}	Stellt die Elemente einer Menge „etwas lesbarer“ dar.
text 1,2,[3,4],{6,7,8..12} ⇨ elements A B C 1 2 3 4 set	Erzeugt aus einem Text die entsprechende Liste von Elementen. Listen werden im Text „eckig“ geklammert, Mengen „geschweift“.

Die folgenden Operationen müssen mit endlichen Mengen ausgeführt werden, weil jeweils alle Elemente verarbeitet werden. Aus diesem Grund gibt es eine obere Schranke für Mengenelemente, die entweder in den *SciSnap!Properties* oder durch den Block in der Mengen-Bibliothek festgelegt wird.

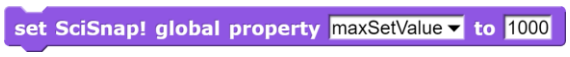	Setzt die Grenze, bis zu der ggf. Prädikate bzw. Intervallgrößen überprüft werden.
	dito
	Liefert die Differenzmenge zweier Mengen.
	Liefert „wahr“, falls die erste Menge Teilmenge der zweiten ist, sonst „falsch“.
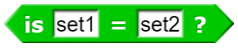	Liefert „wahr“, falls die Mengen die gleichen Elemente enthalten, sonst „falsch“.
	Liefert das kartesische Produkt zweier Mengen.
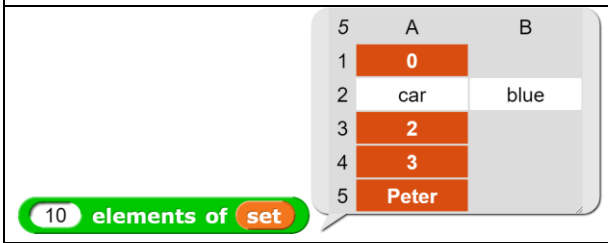	Liefert die ersten n Elemente einer Menge als Liste.
	Fasst eine Liste von Intervallen zusammen.

Weil einerseits die Prädikate der Mengen so eine große Bedeutung haben, andererseits die Verfahren auch in der booleschen Algebra vonnöten sind, wurden zur Set-Bibliothek noch einige weitere Blöcke hinzugefügt.

	Implikation, liefert „wahr“, wenn der Schluss formal stimmt, sonst „falsch“.
	Äquivalenz, liefert „wahr“, wenn die Eingaben formal äquivalent sind, sonst „falsch“.
	Umwandlung von Schaltwerten in Wahrheitswerte.
	Umwandlung von Wahrheitswerten in Schaltwerte.

Beispiele:

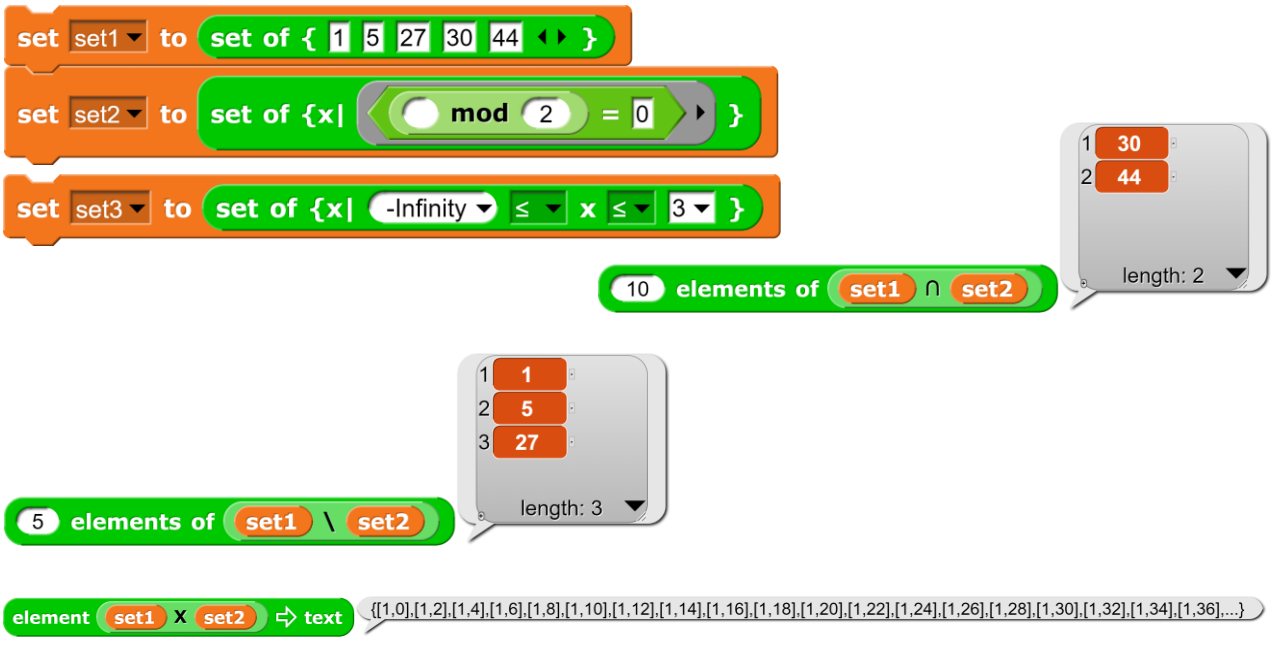

3.1.5 **Numerische Verfahren** (SciSnap!NumericMathLibrary.xml)

Die Bibliothek enthält einige Blöcke zum Umgang mit Folgen, Reihen, Sekanten, Integralen und Nullstellen sowie der Berechnung von Ableitungen an einer bestimmten Stelle.

	Berechnung eines Folgenelements. Der Term muss mit (grauem) Ring eingegeben werden („ringified“). Beispiel: das 17. Element der Folge $\frac{1}{\sqrt{n}}$.
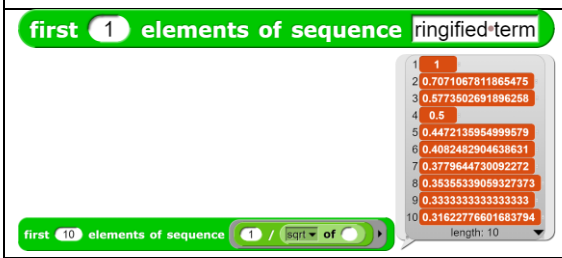	Liefert die ersten n Glieder einer Folge als Liste. Beispiel: Die ersten 10 Elemente der Folge $\frac{1}{\sqrt{n}}$.
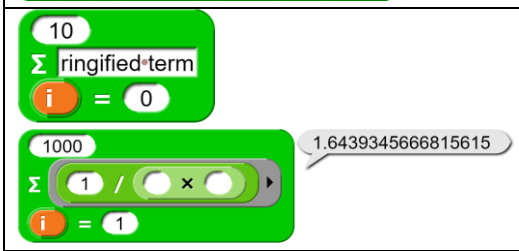	Berechnet die Summe einer endlichen Reihe. Der Term muss mit (grauem) Ring eingegeben werden („ringified“). Beispiel: Die Summe der ersten 1000 Glieder der Reihe $\sum_{i=1}^{1000} \frac{1}{i^2}$.
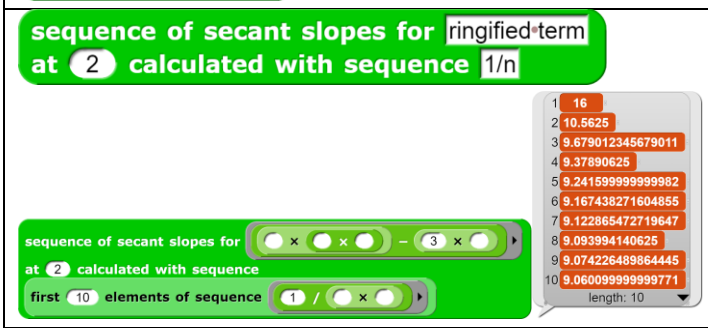	Folge von Sekantensteigungen in einem Punkt. Die Folge kann auch explizit in Form einer Liste angegeben werden. Der Term muss mit (grauem) Ring eingegeben werden („ringified“). Beispiel: 10 Sekantensteigungen in der Nähe des Punkts mit x=2 der Funktion $f(x) = x^3 - 3x$, berechnet mit der Folge $\frac{1}{n^2}$.
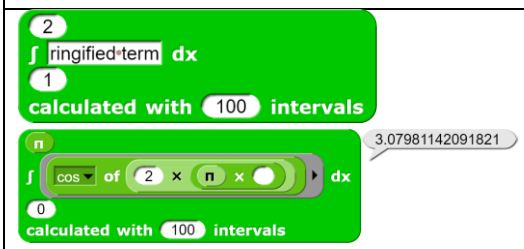	Numerische Berechnung eines Integrals mithilfe des Trapezverfahrens. Der Term muss mit (grauem) Ring eingegeben werden („ringified“). Beispiel: Berechnung des Integrals F=$\int_0^{\pi} \cos 2\pi x \, dx$
	Nullstellenberechnung nach dem Newton-Verfahren. Der Term muss mit (grauem) Ring eingegeben werden („ringified“). Beispiel: Berechnung der Nullstelle von $f(x) = x^3 - 3x$, Start bei x=1.
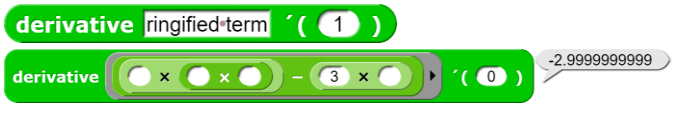	Nummerische Bestimmung der Ableitung in einem Punkt. Der Term muss mit (grauem) Ring eingegeben werden („ringified“). Beispiel: Berechnung der Ableitung von $f(x) = x^3 - 3x$ für x=0.

3.2 Die Daten-Bibliothek (SciSnap!DataLibrary.xml)

Die Daten-Bibliothek von *SciSnap!* dient einerseits zur direkten Manipulation auch größerer Datenmengen, andererseits zur Auswertung von Daten, z. B. zur Berechnung von statistischen Größen wie der Varianz oder Korrelationen. Weil Zahlenstrukturen wie Vektoren und Matrizen in den Mathematik-Bibliotheken implementiert sind, beschränkt sich die Daten-Bibliothek weitgehend auf Tabellen (*tables*) als zusätzliche Struktur. Deren Zeilen und Spalten können entweder über ihre Nummern oder die Bezeichner der ersten Spalte bzw. Zeile identifiziert werden. Spalten können zusätzlich mit großen Buchstaben (*A..Z*) benannt werden. Wird eine Zahl als Bezeichner benötigt (also nicht die Spalten- oder Zeilennummer), dann muss ein Doppelkreuz (#) vor die Zahl als Bezeichner gesetzt werden, z. B. *#123*.

SciSnap!Data

11	A	B	C	D	E
1	party\year	2010	2011	2014	2020
2	AAB	57	62	22	11
3	ACB	9	55	29	28
4	BAD	50	33	10	36
5	KKA	12	21	66	32
6	NZT	45	25	48	49
7	LOH	53	27	43	50
8	TTL	61	36	46	24
9	CAG	18	34	45	61
10	YKL	5	60	41	18
11	ZZT	26	12	39	56

Die folgenden Beispiele beziehen sich auf eine Tabelle, die „Parteinamen“ als erste Spalte und danach „Wahlergebnisse“ in den angegebenen Jahren enthält.

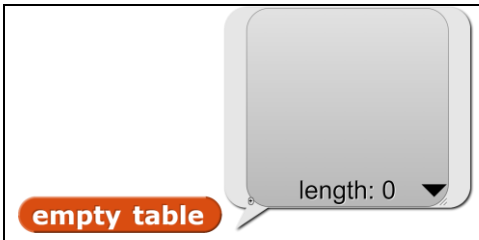	Liefert eine leere Tabelle (als Startstruktur für weitere Tabellenoperationen).
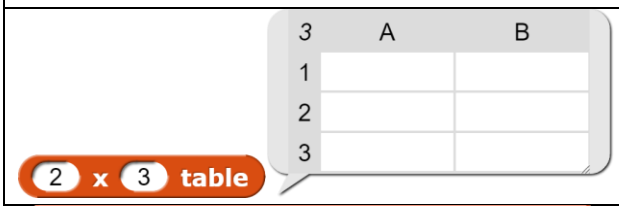	Liefert eine Tabelle der angegebenen Größe ohne Inhalte.
	Liefert eine Tabelle der angegebenen Größe ohne Inhalte, aber mit Spaltenüberschriften.
	Liefert eine Kopie einer Liste oder Tabelle. Da *Snap!* Listen als Referenzen zuweist, kann man mit diesem Block unbeabsichtigte Änderungen am Original vermeiden.
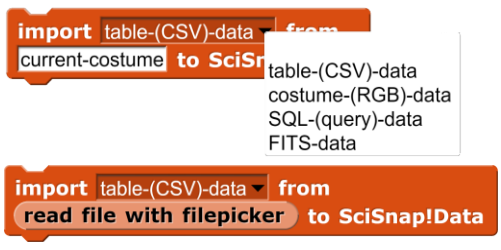	Der Block importiert Tabellen, Bilddaten oder SQL-Daten in die globale Variable *SciSnap!Data*, mit der die anderen Blöcke der Bibliothek per Voreinstellung arbeiten. Beispiel: Import einer Tabelle mithilfe des Datei-Auswahldialogs.
	Startet den Datei-Auswahldialog.

	Schreibt eine Tabelle in eine Datei des Downloadbereichs des Browsers unter dem angegebenen Namen.
	Liefert als Ergebnis eine transponierte Tabelle oder Liste, also eine, bei der Zeilen und Spalten vertauscht wurden.

Die folgenden Blöcke dienen zur direkten Manipulation von Tabellen.

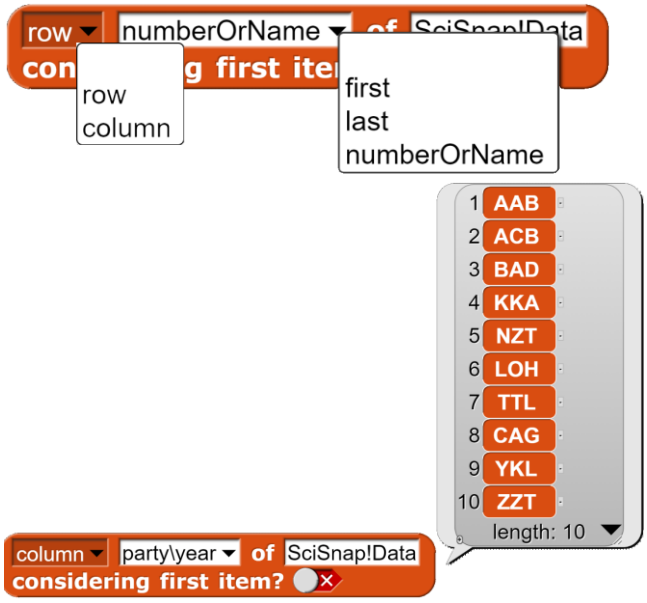	Liefert eine Zeile oder Spalte der angegebenen Tabelle. Beispiel: Die erste Spalte der Beispieltabelle ohne die Überschrift.
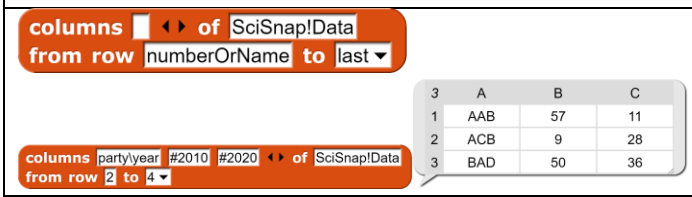	Liefert den angegebenen Zeilenbereich der angegebenen Spalten. Beispiel: Ergebnisse der drei angegebenen Parteien aus 2010 und 2020.
	Fügt der angegebenen Tabelle eine Zeile, eine Spalte oder Spalten-Überschriften hinzu. Fehlende Elemente werden mit leerem Inhalt ergänzt, „überstehende“ werden ignoriert.
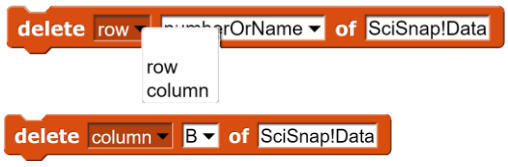	Löscht eine Zeile oder Spalte aus der angegebenen Tabelle. Beispiel: Löscht die Spalte für das Jahr 2010 aus der Beispieltabelle.
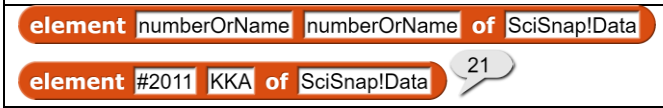	Liefert das angegebene Tabellenelement. Beispiel: Ergebnis der Partei KKA im Jahr 2011.
	Setzt den Wert in einer Tabelle an der angegebenen Stelle.

Die folgenden Blöcke sind sehr viel leistungsfähiger. Die Beispiele beziehen sich wieder auf die Beispieltabelle.

	Liefert die ausgewählte Eigenschaft eines Vektors, also einer Zeile oder Spalte, die nur aus Zahlen besteht.
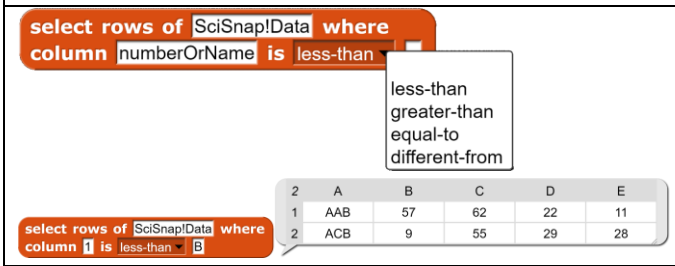	Liefert ausgewählte Zeilen einer Tabelle, die dem genannten Kriterium genügen. Beispiel: Alle Wahlergebnisse mit Parteien, die mit „A“ anfangen.
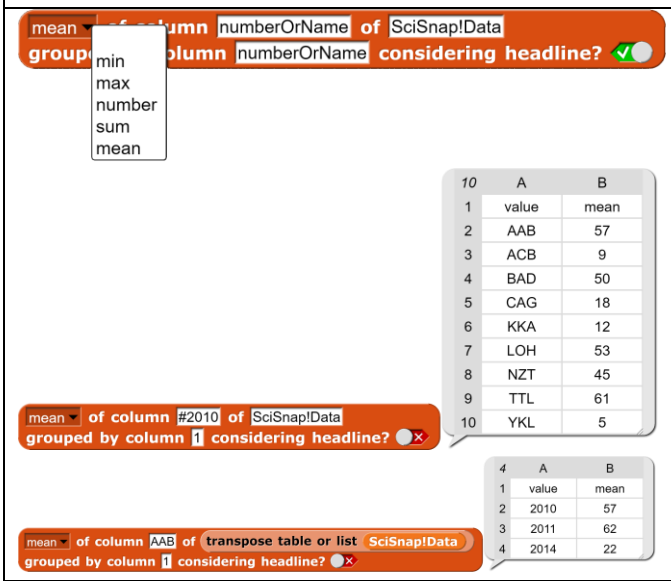	Liefert Minimum, Maximum, Anzahl, Summe oder Mittelwert der ersten angegebenen Spalte der Daten, gruppiert nach der zweiten. Die Überschriften können einbezogen werden – oder nicht. Beispiele: Die Mittelwerte des Jahres 2010, gruppiert nach Parteien. Die Mittelwerte des Partei AAB, gruppiert nach Jahren.
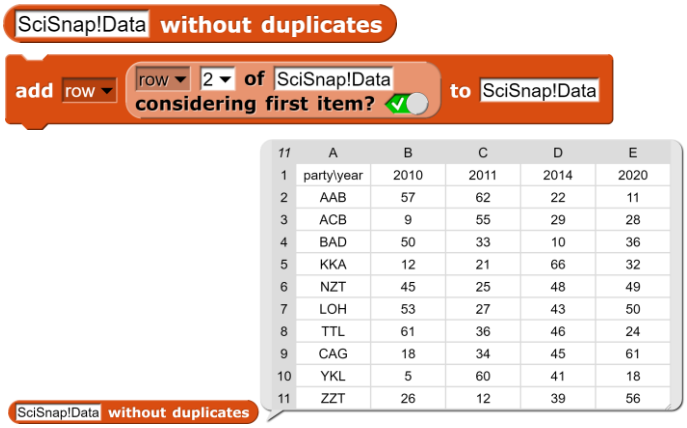	Liefert eine Tabelle ohne doppelte Zeilen oder einen Vektor ohne Duplikate. Beispiel: Wir fügen die erste Zeile der Tabelle noch einmal am Ende ein … …und löschen dann die Duplikate wieder.

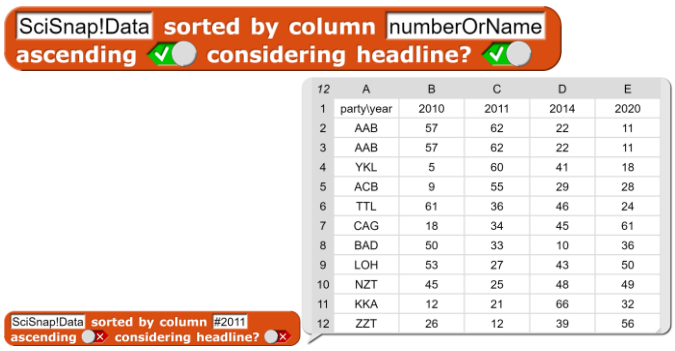	Liefert eine nach der angegebenen Spalte auf- oder absteigend sortierte Tabelle. Beispiel: Die Wahlergebnisse sortiert nach dem Jahr 2011.
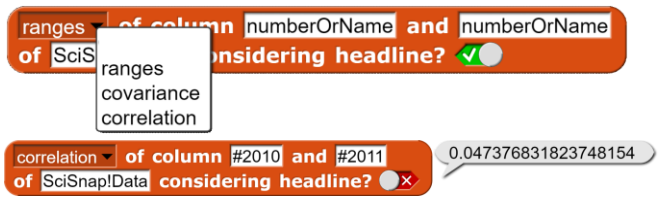	Liefert Bereiche, Kovarianz und Korrelation zwischen zwei Tabellenspalten. Beispiel: Korrelation zwischen den Jahren 2010 und 2011.
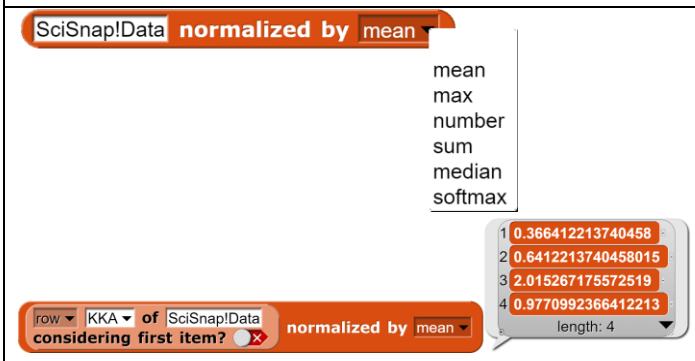	Normalisierung eines Vektors durch Teilen durch den Mittelwert, den Maximalwert, die Anzahl, Summe, Median seiner Werte oder durch die Softmax-Funktion. Beispiel: Ergebnisse der Partei KKA, „normalisiert“ durch den Mittelwert.
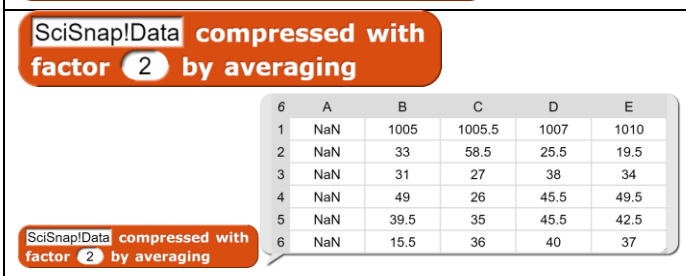	Liefert eine Tabelle, die um den Faktor n durch Mittelwertbildung komprimiert wurde. Texte können so natürlich nicht komprimiert werden.
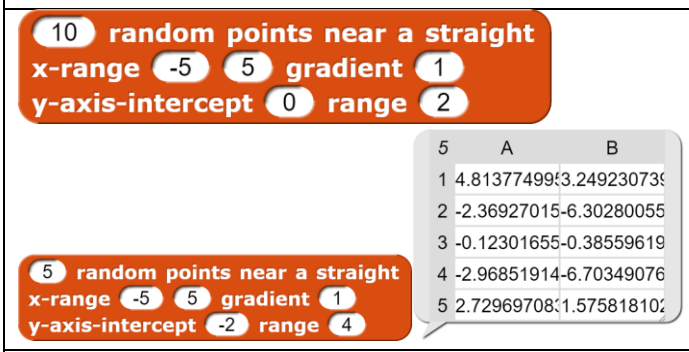	Liefert n Punkte, die um eine Gerade, gegeben durch Steigung und y-Achsenabschnitt, in einem Bereich streuen, der durch „range“ begrenzt wird. Dient meist zu Testzwecken. Beispiel: 5 Punkte, die um $f(x) = x - 2$ streuen.
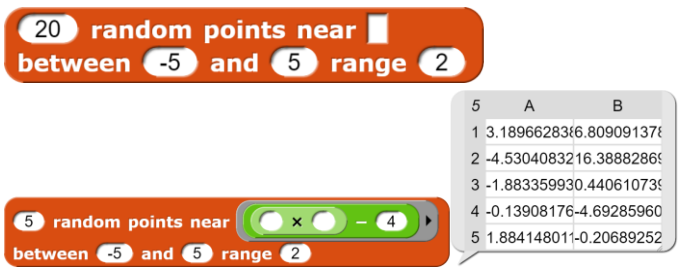	Liefert n Punkte, die um eine beliebige Funktion, gegeben durch ihre „ringified“ Operatoren, in einem Bereich streuen, der durch „range“ begrenzt wird. Dient meist zu Testzwecken. Beispiel: 5 Punkte, die um $f(x) = x^2 - 4$ streuen.

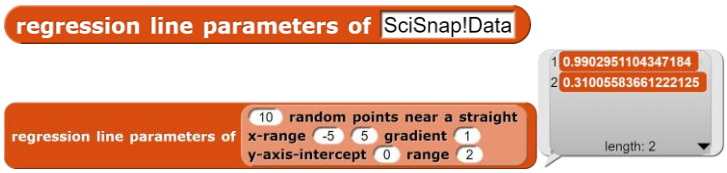	Liefert Steigung und y-Achsenabschnitt der Regressionsgerade durch die angegebenen Daten. Beispiel: Regressionsgerade durch 10 Zufallspunkte, die um eine Gerade streuen.
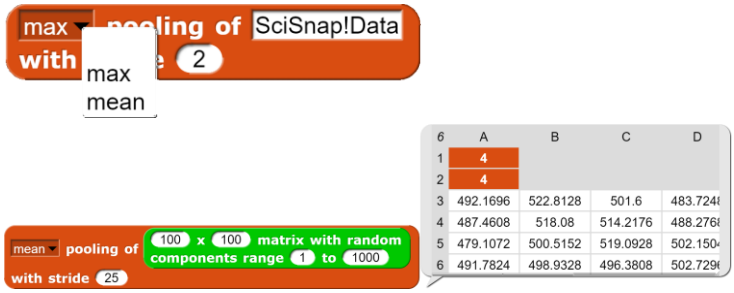	Liefert eine Tabelle, die durch max- oder mean-Pooling mit der Schrittweite n komprimiert wurde. Vor dem Resultat werden die Dimensionen der neuen Tabelle übergeben. Gut anwendbar auf Bilddaten. Beispiel: Eine Matrix aus 100x100 Zufallszahlen wird mit der Schrittweite 25 komprimiert.
	k-Nächste-Nachbarn-(kNN)-Verfahren in zwei Dimensionen für maschinelles Lernen. Beispiel: HR-Diagramm
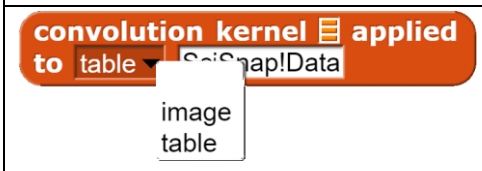	Liefert das Ergebnis einer Faltung (convolution) angewandt entweder auf eine Tabelle oder ein auf Bilddaten. Beispiel: Kantenerkennung, CNN
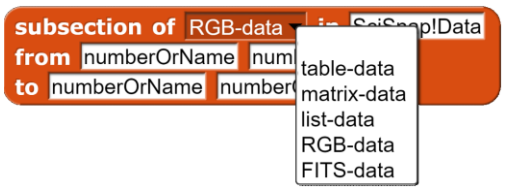	Liefert einen Ausschnitt aus einer Tabelle, einer Matrix, einer Liste oder aus Bilddaten, der durch die beiden Punkte „links-oben“ und „rechts-unten“ gegeben ist.
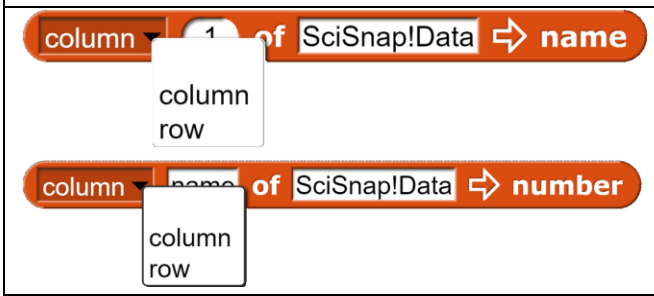	Liefert die Zeilen- oder Spaltennummer einer Tabelle mit der angegebenen Bezeichnung bzw. umgekehrt.
	Liefert n Zufallspunkte aus dem angegebenen Bereich.
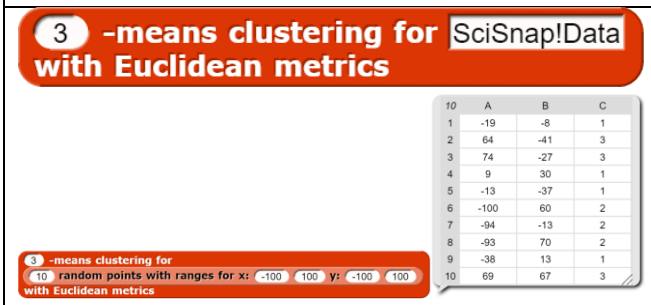	Clustering von n-dimensionalen Daten mit der k-means-Methode. Als Metrik wird der Euklidische Abstand genommen. Cluster-Nummern werden an die Daten angehängt.
	Clustering mit beliebiger Metrik.
	Liefert die Levenshtein-Distanz.

3.3 Die SQL-Bibliothek (SciSnap!SQLLibrary.xml)

Die *SQL*-Bibliothek enthält die meisten Befehle, die für SQL-Abfragen (*Select*) erforderlich sind. Andere *SQL*-Anweisungen können direkt in den *exec SQL-command*-Block eingegeben werden. Allerdings muss man dann auch über die entsprechenden Zugriffsrechte verfügen. Die Bibliothek arbeitet mit zwei globalen Variablen *SQLData* und *SQL-Properties*, die verhindern, dass die darin gespeicherten Daten mit denen anderer Sprites in Konflikt geraten. Die Variablen werden automatisch bei der Konfiguration erzeugt.

Ähnlich wie die Mathematik- und Data-Blöcke arbeiten die *SQL*-Blöcke nicht mit einem bestimmten Sprite oder der Bühne. Bei jedem Aufruf wird aber zuerst geprüft, ob *SciSnap!* erfolgreich für *SQL*-Zugriffe konfiguriert wurde. Ist das nicht der Fall, erfolgt eine Fehlermeldung – bei *Reporter*-Blöcken als Ergebnis des Funktionsaufrufs, bei *Command*-Blöcken als Ausgabe des rufenden Sprites sowie in der *SciSnap!*-Sammelbox für Fehlermeldungen *SciSnap!Messages*.

	Konfiguriert *SciSnap!* für *SQL*-Zugriffe. Dafür werden die globalen Variablen *SQLData* und *SQLProperties* erzeugt und die Anfangs-Eigenschaften werden gesetzt. Das Sprite, das den Befehl ausführt, nimmt das Kostüm *SQLDisconnected* an, falls es vorhanden ist. 
	Liefert bei korrekter Konfiguration „wahr“, sonst „falsch“.
	Verbindet mit einem Datenbank-Server, dessen Adresse im Skript steht. Dieser sollte neu eingestellt werden, z. B. als *localhost*, wenn nicht der voreingestellte Server benutzt wird. Ist der Verbindungsversuch erfolgreich, nimmt das ausführende Sprite das Kostüm *SQLConnected* an, falls es vorhanden ist. 
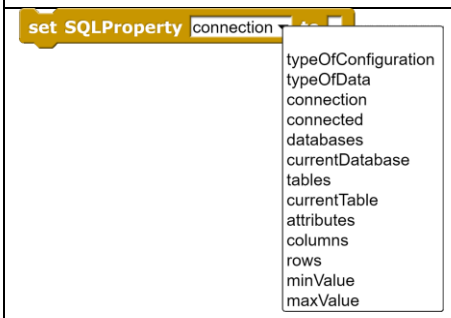	Setzt eine der Eigenschaften in *SQLProperties* auf den angegebenen Wert.
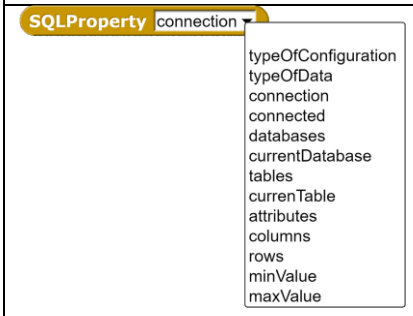	Liefert eine der Eigenschaften in *SQLProperties*.

	Importiert eine Tabelle in den Datenbereich *SQLData*. Beispiel: Import eines Abfrageergebnisses.
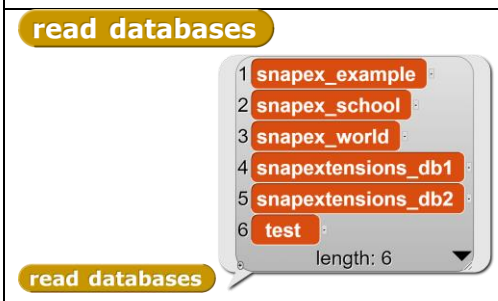	Liefert eine Liste der aktuell verfügbaren Datenbanken.
	Wählt eine der vorhandenen Datenbanken aus.
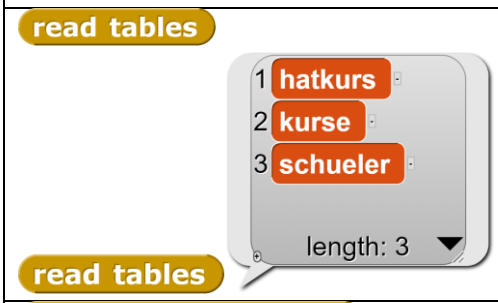	Liefert eine Liste der Tabellen der ausgewählten Datenbank.
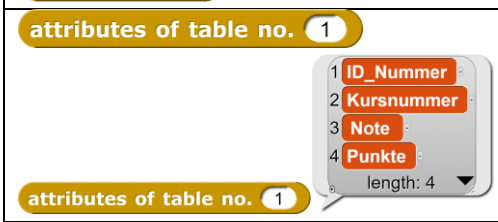	Liefert eine Liste der Attribute der angegebenen Tabelle.
	Block zur Erzeugung einfacher SQL-Abfragen, die vom Block *exec SQL-command* ausgeführt werden können.
	Block zur Erzeugung komplexer SQL-Abfragen, die vom Block *exec SQL-command* ausgeführt werden können.
	Block zur Ausführung von SQL-Anweisungen an eine Datenbank. Die Anweisungen können durch *Select*-Blöcke erzeugt oder direkt eingegeben werden.
	Prädikate zur Ausführung von Vergleichen.
	Prädikate zur Ausführung logischer Verknüpfungen.
	Prädikat zur Überprüfung eines Zeichenkettenmusters.
	Prädikat zum Überprüfen, ob ein Element in einer Aufzählung enthalten ist.
	Aggregatfunktionen.

Die folgenden *SciSnap!*-Bibliotheken arbeiten mit lokal konfigurierten *Spezial-Sprites*. Diese sind konzeptionell von *Sketchpads* abgeleitet, dienen also zur Anfertigung von Skizzen, zum Experimentieren, zum Ausprobieren der Wirkung von Befehlen usw. Ist das *Pad* zu voll, dann wird eben eine neue „Seite“ davon genommen und weitergearbeitet.

Jedes Sprite und die Bühne können als *Spezial-Sprite* dienen. Dafür werden sie entsprechend konfiguriert, indem zwei lokale Variable *myData* und *myProperties* erzeugt und mit Anfangswerten gefüllt werden. Die Befehle, die sich auf ein *Spezial-Sprite* beziehen, enthalten alle das Ziel der Operation – also ein Sprite oder die Bühne. Vor der Ausführung der Anweisungen wird jeweils überprüft, ob das Ziel richtig konfiguriert worden ist. Danach wird mit den lokalen Daten und Eigenschaften des Ziels gearbeitet. Dieses Vorgehen erübrigt einerseits weitgehend objektorientierte Aufrufe, die die Befehlsblöcke sehr verlängern, wenn Daten übergeben werden müssen, andererseits hält es die Daten lokal bei den Sprites, die die Operationen betreffen. Werden z. B. Daten in einem Bild gemessen und in einem Diagramm dargestellt, dann können das *ImagePad* und das *PlotPad* unabhängig voneinander mit ihren jeweils eigenen Daten und Eigenschaften arbeiten. Die Anfangseinstellungen ermöglichen es, mit halbwegs sinnvollen Voreinstellungen zu arbeiten. Stellt sich im Ergebnis heraus, dass andere Einstellungen sinnvoller wären, dann werden die Voreinstellungen geändert – aber auch nur dann. Diese Arbeitsweise ermöglicht es, bei den einzelnen Blöcken mit relativ wenigen Parametern auszukommen. Die Properties sind weitgehend zu Gruppen zusammengefasst, etwa bei den Eigenschaften der zu zeichnenden Linien. Damit können sie „auf einen Schlag“ übergeben oder gelesen werden und ihre Anzahl hält sich in Grenzen.

3.4 Die ImagePad-Bibliothek (SciSnap!ImagePadLibrary.xml)

ImagePads dienen zur Darstellung von Bilddaten, also zur Erzeugung von Bildern. In diesen Bildern kann dann z. B. mithilfe der Maus gemessen werden – z. B. kann ein Schnitt durch das Bild erzeugt werden. Zusätzlich stehen einige der üblichen Operationen zum Zeichnen von Linien, Rechtecken, Kreisen und Texten zur Verfügung. Das Koordinatensystem auf *ImagePads* ist das für Bilder übliche: der Ursprung liegt in der oberen linken Ecke und die y-Achse ist nach unten gerichtet.

	Konfiguriert ein Sprite oder die Bühne als *ImagePad*. Der Name von *„anotherSprite“* muss bei Bedarf angegeben werden. Der Befehl ist einmal auszuführen, bevor mit einem Sprite als *ImagePad* gearbeitet werden kann. Das Ziel des Aufrufs nimmt ein rechteckiges Kostüm mit den angegebenen Maßen und Farben an.
	Liefert bei korrekter Konfiguration „wahr“, sonst „falsch“.
	Liefert eine der Eigenschaften in *myProperties*.
	Setzt eine der Eigenschaften in *myProperties* auf den angegebenen Wert.
	Setzt die Kostüm-Eigenschaften des angegebenen Ziels.
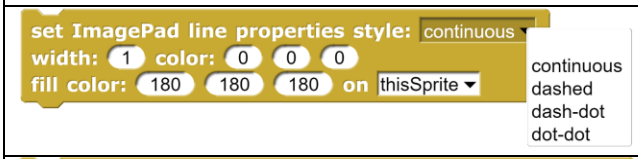	Setzt die Linien-Eigenschaften des angegebenen Ziels.
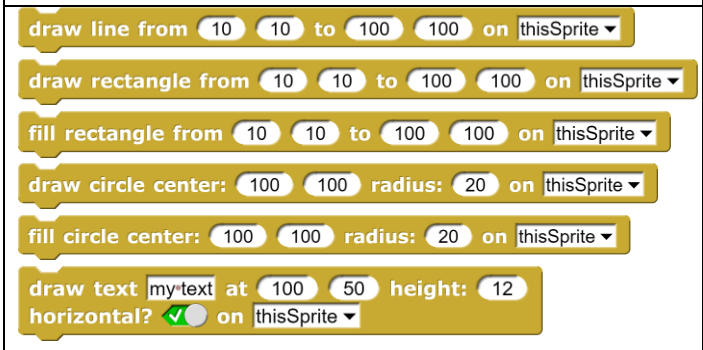	elementare Zeichenoperationen
	Zeichnet eine Liste von "Punkten" als Kreise oder Quadrate mit JS-Koordinaten.

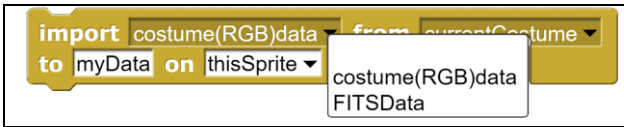	Importiert Bilddaten.
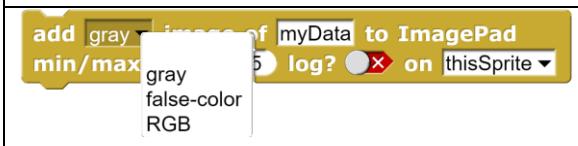	Erzeugt aus den Bilddaten ein Bild auf einem *ImagePad*.
	Liefert das Ergebnis einer affinen Transformation eines Kostüms, die durch die Angabe von drei Originalpunkten und drei Bildpunkten beschrieben wird.
	Startet den Datei-Auswahldialog.
	Setzt ein Pixel des Kostüms auf den angegebenen Wert.
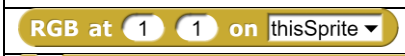	Liefert den Wert eines Pixels des Kostüms.
	Setzt einen Bildpunkt im Datenbereich auf den angegebenen Wert.
	Liefert den Wert eines Bildpunktes aus dem Datenbereich.
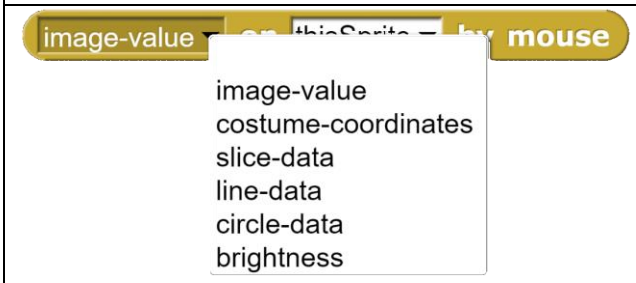	Liefert Bilddaten mithilfe der Maus: einzelne Bildwerte, Bildkoordinaten, Schnitte durch das Bild, Endpunkte einer Linie oder Daten eines Kreises sowie Helligkeitswerte aus einem Bereich.
	Liefert die Gesamthelligkeit um einen Bildpunkt im angegebenen Radius.
	Zeichnet eine Liste von "Punkten" als Kreise oder Quadrate. Achtung! Es werden JS-Koordinaten verwendet!

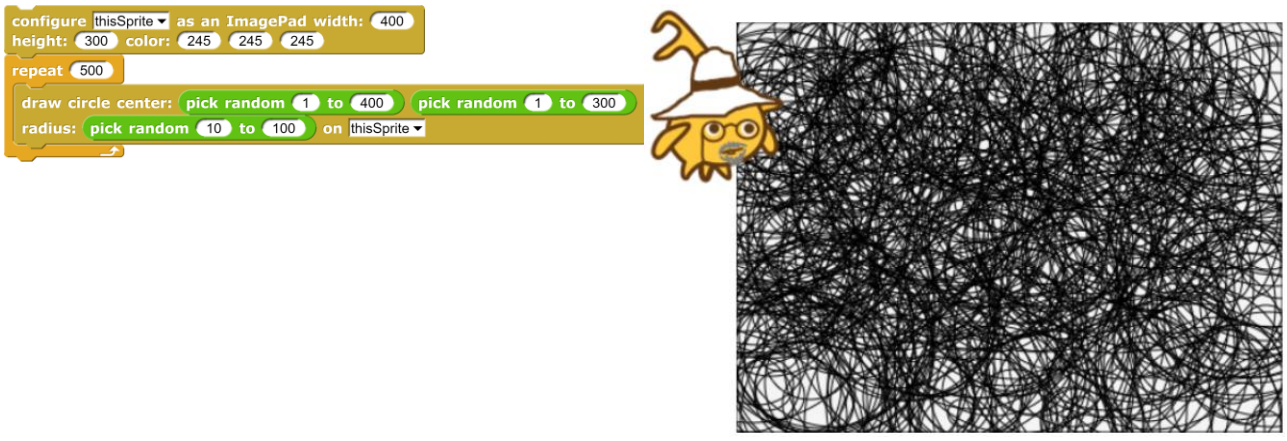

3.5 Die PlotPad-Bibliothek (SciSnap!PlotPadLibrary.xml)

PlotPads dienen zur Darstellung von Diagrammen, Histogrammen usw. Die aktuelle *SciSnap!PlotPadLibrary* wurde stark von *Rick Hessman* gestaltet, insbesondere das *PrettyPrinting* und die *Linienstile* stammen von ihm. Vielen Dank dafür!

	Konfiguriert ein Sprite oder die Bühne als *PlotPad*. Der Name von *„anotherSprite“* muss bei Bedarf angegeben werden. Der Befehl ist einmal auszuführen, bevor mit einem Sprite als *PlotPad* gearbeitet werden kann. Das Ziel des Aufrufs nimmt ein rechteckiges Kostüm mit den angegebenen Maßen und Farben an.
	Liefert bei korrekter Konfiguration „wahr“, sonst „falsch“.
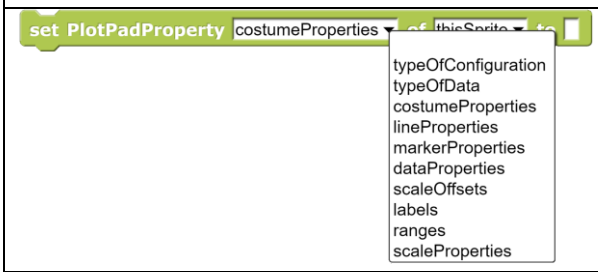	Setzt eine der Eigenschaften in *myProperties* auf den angegebenen Wert.
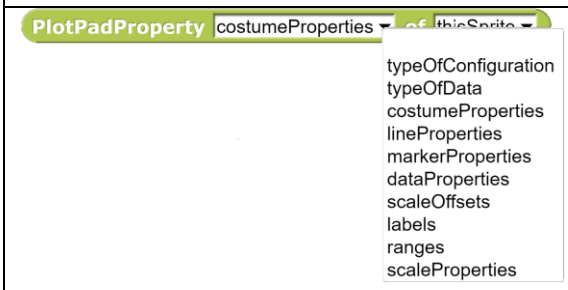	Liefert eine der Eigenschaften in *myProperties*.
	Setzt die Kostüm-Eigenschaften des angegebenen Ziels.
	Setzt die Linien-Eigenschaften des angegebenen Ziels.
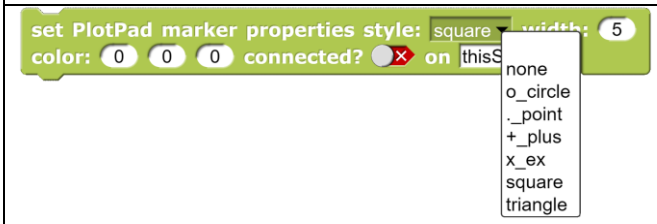	Setzt die Datenpunkt-Eigenschaften des angegebenen Ziels.
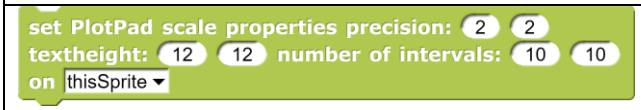	Setzt die Skalen-Eigenschaften des angegebenen Ziels.
	Setzt die Beschriftungs-Eigenschaften des angegebenen Ziels.

set PlotPad offsets from edges on thisSprite	Berechnet die Abstände der Koordinatenachsen von den Rändern.
set PlotPad ranges for x: -10 10 y: -10 10 with border? of 0.1 pretty formatted? on thisSprite	Setzt die Zahlenbereiche der Achsen des Koordinatensystems.
set pretty ranges on PlotPad thisSprite	Setzt die Zahlenbereiche so, dass „schöne“ Beschriftungen an den Achsen stehen.
pretty values for a PlotPad from -10 to 10 with 6 intervals	Liefert Werte für „schöne“ Beschriftungen der Achsen.
get ranges for PlotPad thisSprite from myData with border 0.1	Bestimmt die Zahlenbereiche neu, berechnet aus den Daten.
ranges of 2-dim table	Liefert die Zahlenbereiche einer zweidimensionalen Tabelle.
add graph ringified operator or polynomial to PlotPad thisSprite	Fügt dem *PlotPad* einen Funktionsgraphen hinzu, der als Liste von Polynom-Koeffizienten oder als „ringified“ Term gegeben ist.
add dataplot of numeric data: myData to PlotPad thisSprite	Fügt dem *PlotPad* einen Datenplot für eine zweidimensionale Datentabelle hinzu.
add dataplot of mixed data: myData y-scale? x-scale? to PlotPad thisSprite	Fügt dem *PlotPad* einen Datenplot für eine zweidimensionale Tabelle hinzu, die in der ersten Spalte Texte, in der zweiten Zahlenwerte enthält.
add histogram of myData with 10 groups pretty formated? to PlotPad thisSprite	Fügt dem *PlotPad* ein Histogramm hinzu.
add axes and scales to PlotPad thisSprite	Fügt dem *PlotPad* Achsen und Beschriftungen hinzu.
clear plot of thisSprite	Löscht die bisherigen Plots.
convert value 100 to coordinate xp of PlotPad thisSprite (xp, yp, x, y)	Liefert die Umrechnung eines Zahlenwerts in Koordinaten des *Plotpads* oder des Koordinatensystems.
PlotPad costume-coordinates mouse (costume-coordinates, graph-coordinates)	Rechnet die Mausposition in Kostüm- bzw. Graph-Koordinaten um.
SIMPLE PLOT of data: x: 0 y: 0 width: 600 height: 400 title: labels: line: continuous marker: square color: 0 0 0	Einfaches Plotprogramm für Daten.

```
configure thisSprite as a PlotPad width: 400
height: 300 color: 245 245 245
set PlotPad ranges for x: 0 1000 y: -1 1
with border? of 0.1 pretty formatted?
on thisSprite
add graph sin of to PlotPad thisSprite
add axes and scales to PlotPad thisSprite
```

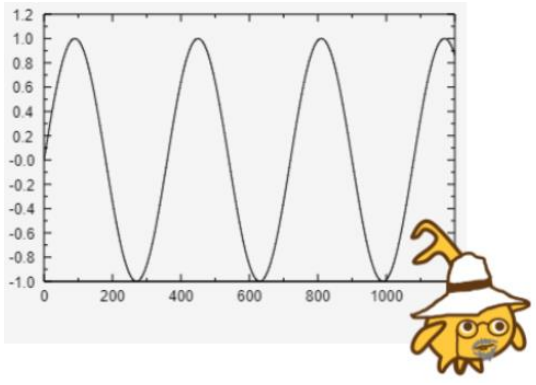

3.6 Die GraphPad-Bibliothek (SciSnap!GraphPadLibrary.xml)

Graphen sind eines der mächtigsten Modelle der Informatik. Mit ihrer Hilfe lassen sich komplexe Systeme, vor allem aber die Auswirkung der Vernetzung zahlreicher ähnlicher Teilsysteme, studieren. Die dafür erforderlichen Algorithmen wie Breitensuche oder Routing sind selbst aber nicht trivial, sodass es sinnvoll erscheint, diese als Basisbefehle zur Verfügung zu stellen, um die Arbeit auf die Modellierung selbst zu konzentrieren. Genau das ist der Zweck der *SciSnap!GraphPadLibrary*.

	Konfiguriert ein Sprite oder die Bühne als *GraphPad*. Der Name von *„anotherSprite“* muss bei Bedarf angegeben werden. Der Befehl ist einmal auszuführen, bevor mit einem Sprite als *GraphPad* gearbeitet werden kann. Das Ziel des Aufrufs nimmt ein rechteckiges Kostüm mit den angegebenen Maßen und Farben an.
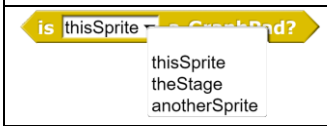	Liefert bei korrekter Konfiguration „wahr“, sonst „falsch“.
	Setzt eine der Eigenschaften in *myProperties* auf den angegebenen Wert.
	Liefert eine der Eigenschaften in *myProperties*.
	Setzt die Kostüm-Eigenschaften des angegebenen Ziels.
	Setzt die Knoten-Eigenschaften des angegebenen Ziels.
	Setzt die Kanten-Eigenschaften des angegebenen Ziels.
	Fügt dem Graph n Knoten an Zufallspositionen hinzu.
	Fügt dem Graph einen Knoten an der angegebenen Position hinzu.
	Bewegt einen Knoten zu der angegebenen Position.
	Fügt dem Graph n zufällig gewählte Kanten hinzu.
	Fügt dem Graph eine Kante zwischen den genannten Knoten hinzu.
	Zeichnet den Graph. Färbt verbundene Knoten in der gleichen Farbe.

change weight of edge from vertex 1 to vertex 2 to 1 of graph on thisSprite	Verändert das Gewicht einer Kante, wenn möglich.
weight of edge from vertex 1 to vertex 2 of graph on thisSprite	Liefert das Gewicht einer Kante, wenn möglich.
change content of vertex 1 to of graph on thisSprite	Verändert den Inhalt eines Knotens.
content of vertex 1 of graph on thisSprite	Liefert den Inhalt eines Knotens.
ask for new weight of graph on thisSprite	Erfragt ein neues Kantengewicht.
ask for new vertex content in graph on thisSprite	Erfragt einen neuen Knoteninhalt.
ask for new start vertex width of graph on thisSprite	Erfragt eine neue Start-Knotengröße.
delete vertex 1 of graph on thisSprite	Löscht einen Knoten des Graphen.
delete edge from vertex 1 to vertex 2 of graph on thisSprite	Löscht eine Kante des Graphen.
set marker of vertex 1 of graph on thisSprite	Markiert einen Knoten.
remove marker of vertex 1 of graph on thisSprite	Löscht die Markierung eines Knotens.
remove all markers of graph on thisSprite	Löscht alle Markierungen im Graph.
depth first search of content starting at vertex 1 of graph on thisSprite	Tiefensuche ab Knoten mit der genannten Nummer nach einem Inhalt.
breadth first search of content starting at vertex 1 of graph on thisSprite	Breitensuche ab Knoten mit der genannten Nummer nach einem Inhalt.
distance on thisSprite from vertex 1 to vertex 2	Räumlicher Abstand zweier Knoten auf dem Sprite.
shortest path in graph from vertex 1 to vertex 2 on thisSprite	Kürzester Weg zwischen zwei Knoten im Graph.
list of all shortest paths in graph from vertex 1 to all connected vertices of graph on thisSprite	Liste aller kürzesten Wege eines Knotens zu allen verbundenen Knoten im Graph.
vertexnumber at 100 50 of graph on thisSprite	Nummer eines Knotens an der genannten Position auf dem Sprite.
point 0 0 on stage ⇨ point on graph thisSprite	Rechnet Stage-Koordinaten in Graph-(JS)-Koordinaten um.
vertexnumber of Peter in graph of thisSprite	Liefert die Nummer des Knotens mit dem angegebenen Inhalt.

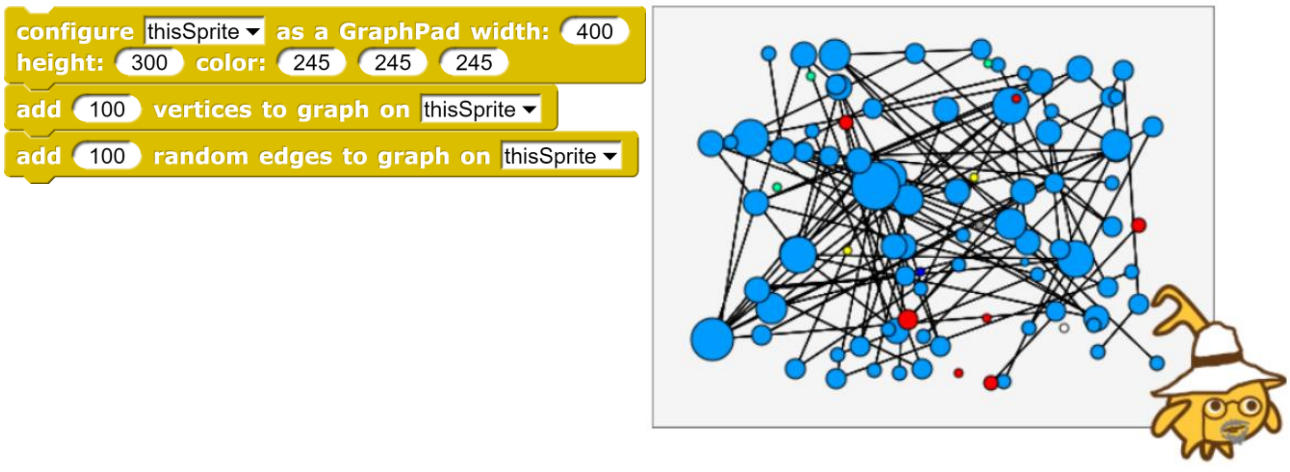

3.7 Die NeuralNetPad-Bibliothek (SciSnap!NNPadLibrary.xml)

Die Grundprinzipien Neuronaler Netze sind zwar einfach und einleuchtend, die Lernverfahren der Systeme aber mit ihrem diskreten Gradientenabstieg und den damit verbundenen partiellen Ableitungen für Mathematikferne nicht so leicht zu durchdringen. Insbesondere ist nicht so leicht zu verstehen, was ein Neuronales Netz eigentlich gelernt hat. Die *SciSnap!NNPadLibrary* soll den Umgang mit Neuronalen Netzen auf einer Zwischenebene zwischen sehr kleinen und wirklich großen Netzen ermöglichen. Sie veranschaulicht die Belegung der Kanten durch Färbungen, wobei positive Werte in grünen und negative in roten Farben dargestellt werden. Kleine Werte sind eher schwarz. Die Bibliothek erleichtert das Erzeugen und das Training voll verbundener Perzeptron-Netze.

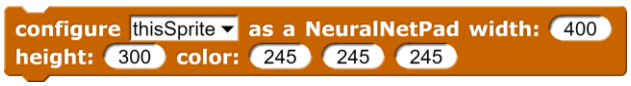	Konfiguriert ein Sprite oder die Bühne als *NNPad*. Der Name von *„anotherSprite“* muss bei Bedarf angegeben werden. Der Befehl ist einmal auszuführen, bevor mit einem Sprite als *NNPad* gearbeitet werden kann. Das Ziel des Aufrufs nimmt ein rechteckiges Kostüm mit den angegebenen Maßen und Farben an.
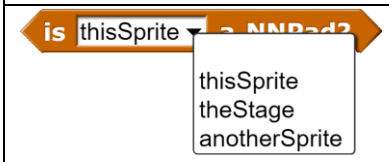	Liefert bei korrekter Konfiguration „wahr“, sonst „falsch“.
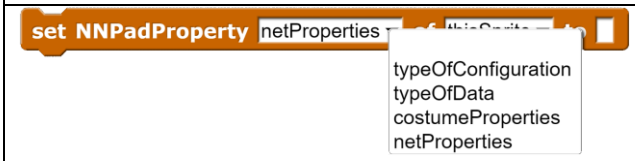	Setzt eine der Eigenschaften in *myProperties* auf den angegebenen Wert.
	Liefert eine der Eigenschaften in *myProperties*.
	Setzt die Kostüm-Eigenschaften des angegebenen Ziels.
	Setzt die Schicht-Eigenschaften des angegebenen Ziels.
	Fügt zufällige Gewicht für ein NN der angegebenen Breite und Tiefe.
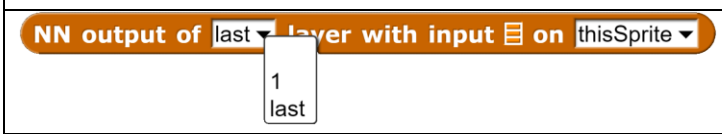	Liefert die Ausgabe der n-ten Schicht des NN beim angegebenen Eingabevektor.
	Zeigt den Status des Netzes beim angegebenen Eingabevektor farblich kodiert an.
	Trainiert das NN beim angegebenen Eingabevektor zur Erreichung des gegebene Ausgabevektors.

4 Datenimport und -export

Snap! kann eine Reihe von Datenformaten direkt importieren. Das kann geschehen, indem man entsprechende Dateien auf das *Snap!*-Fenster „fallen“ lässt oder sie durch Rechtsklick auf einen Variablen-Watcher[18] importiert. Beides klappt gut mit Text-, CSV- und JSON-Dateien. Andere Text-Dateiformate wie FITS kann man ebenfalls so importieren, wobei nachgefragt wird, ob man es ernst meint. Das Exportieren funktioniert auf die gleiche Art. Will man dasselbe programmgesteuert machen, dann benutzt man den Reporter-Block ***read file with filepicker***. Es erscheint ein Dateimanager-Fenster, in dem man die Datei wie üblich auswählt. Danach werden die Daten importiert.

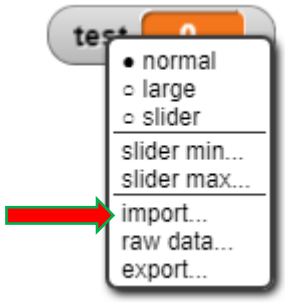

Als wesentliche Aufgabe bleibt anschließend, diese Daten der *SciSnap!Data*-Variablen zuzuweisen und die entsprechenden Eigenschaften in *SciSnap!Properties* zu setzen. Das wird von dem folgenden Block erledigt, der Daten von außen in den *SciSnap!Data*-Bereich importiert. Dabei kann es sich um Bilddaten, Tabellendaten oder die Daten des aktuellen Kostüms handeln. Dieses wird als Tabelle von RGB-Werten gespeichert.

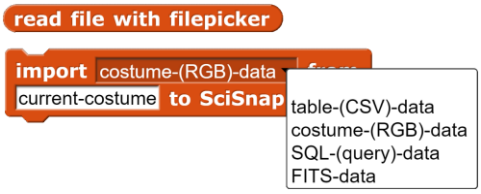

Beispiel: Falschfarbenbild

Durch ein *ImagePad* wird ein Bild (Quelle: [NASA]) gespeichert und mit Falschfarben neu dargestellt.

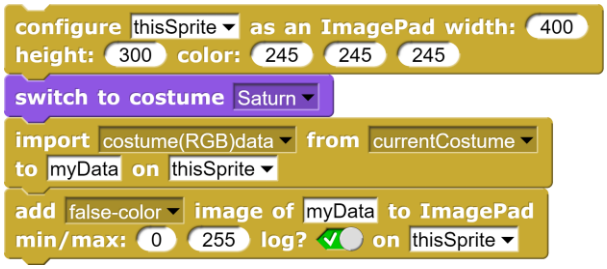

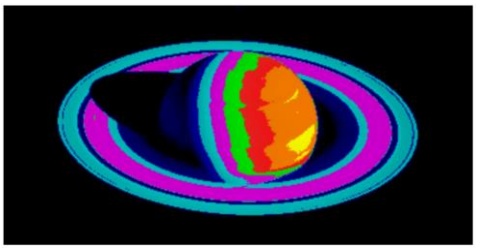

Beispiel: CSV-Import

Knapp 600000 Datensätze aus einer CSV-Datei werden in etwa 10 Sekunden eingelesen. Die Eigenschaften werden gesetzt.

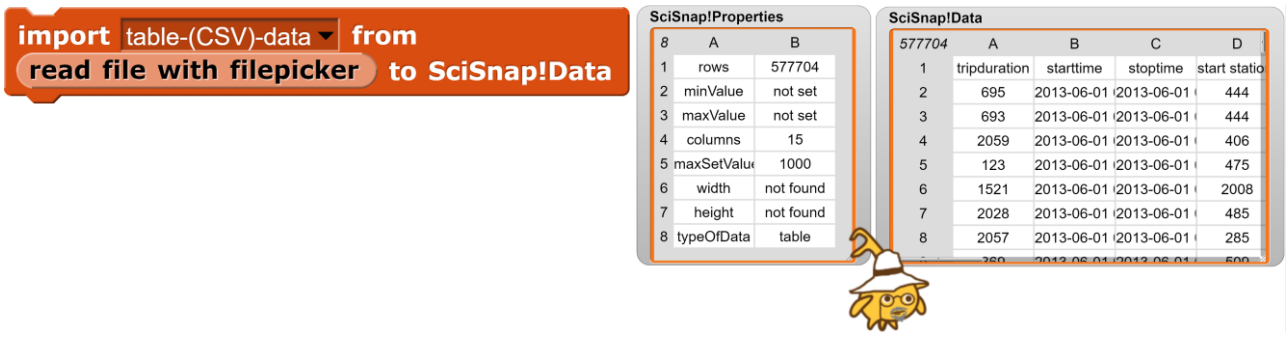

[18] Einen Variablen-Watcher erhält man, wenn man im Kästchen neben der Variablen einen Haken setzt.

Beispiel: SQL-Import

Haben wir Zugang zu einem SQL-Server, dann können wir auch von dort Daten einlesen. In unserem Fall importieren wir mithilfe der *SciSnap!SQL-Library* die Ergebnisse einer Abfrage in die Variable *SQLData*. Dabei werden die Daten in Tabellenform umgesetzt und ihre relevanten Eigenschaften wie Anzahl der Spalten und Zeilen, … in den *SQLProperties* neu gesetzt.

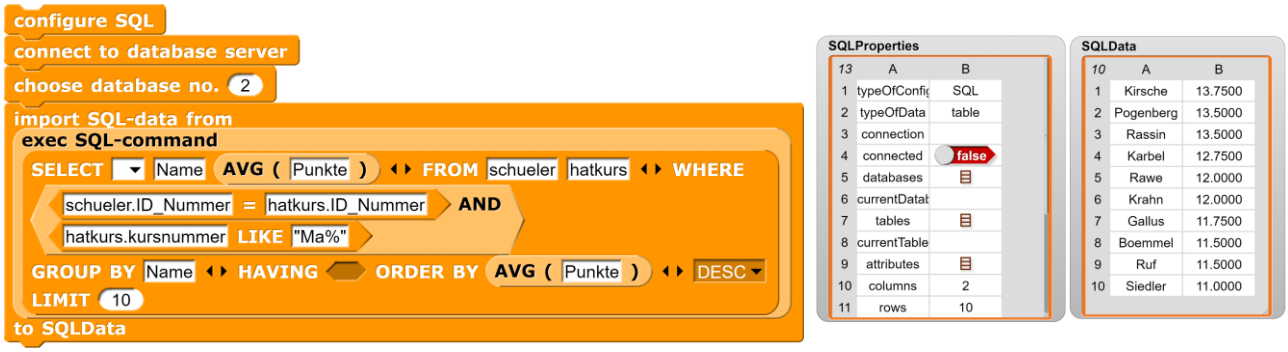

Beispiel: JSON-Import

Der einfachste Weg ist auch hier, eine JSON-Datei einfach ins *Snap!*-Fenster „fallen“ zu lassen. Es geht aber auch automatisiert. Zuerst einmal suchen wir uns interessante JSON-Daten und wählen dafür natürlich die Statistik der Baby-Namen in New York City – was sonst. Der geeignete Block dafür ist wieder ***import** <table data> **from** <read file with filepicker> **to SciSnap!Data***. Das Ergebnis ist eine Liste mit zwei Spalten und zwei Reihen, den Metadaten und den eigentlichen Daten. Weil wir uns für die interessieren, ersetzen wir die Originaldaten durch das Element (2|2) der Tabelle. Natürlich haben wir uns vorher die einzelnen Elemente in Tabellenform angesehen, um zu prüfen, was wir da überhaupt geladen haben. Von den vielen Spalten kopieren wir die drei interessanten in eine neue Tabelle, fügen Spaltenüberschriften hinzu und importieren das Ergebnis wieder in *SciSnap!Data*.

SciSnap!Data

2	A	B
1	meta	
2	data	

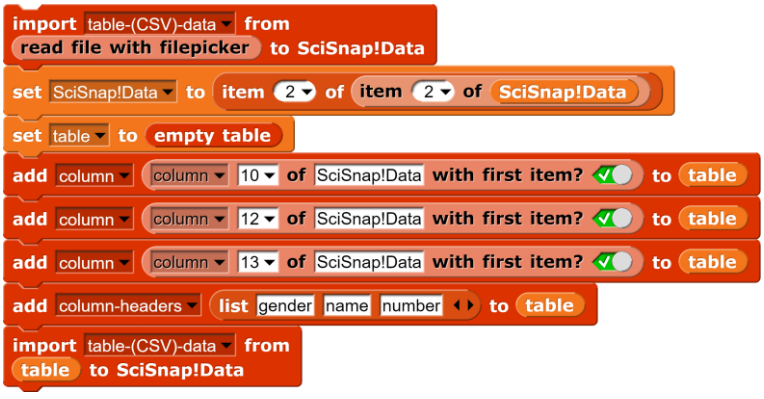

Das Ergebnis: 19419 Babynamen - Wer hätte das gedacht!

table

19419	A	B	C
1	gender	name	number
2	FEMALE	Olivia	172
3	FEMALE	Chloe	112
4	FEMALE	Sophia	104
5	FEMALE	Emily	99
6	FEMALE	Emma	99
7	FEMALE	Mia	79
8	FEMALE	Charlotte	59
9	FEMALE	Sarah	57
10	FEMALE	Isabella	56
11	FEMALE	Hannah	56
12	FEMALE	Grace	54
13	FEMALE	Angela	54
14	FEMALE	Ava	53
15	FEMALE	Joanna	49

Beispiel: Datenimport mit der Maus

In vielen Fällen ist es gerade bei Bildern vorteilhaft, Daten mithilfe der Maus einzulesen. Dafür verfügen *ImagePads* über einen Block, mit dem Bildwerte, Bildkoordinaten, die Daten auf einem Schnitt durchs Bild, Anfangs- und Endpunkt einer Linie, Mittelpunkt und Radius eines Kreises und die summierten Helligkeitswerte zusammen mit deren Zahl in einem Kreis bestimmt werden können. Als Beispiel soll die Höhe antiker Säulen vermessen werden. Dazu wird das Kostümbild des *ImagePads* mit den Säulen importiert und anschließend mit der Maus ausgemessen (gelbe Linie).

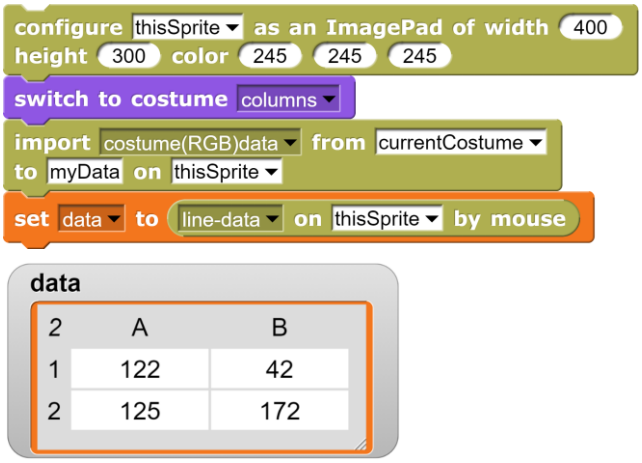

Als zweites Beispiel für das Messen mit der Maus wollen wir die Gesamthelligkeit innerhalb eines Kreises um ein Sternfoto messen (Quelle: [HOU]).

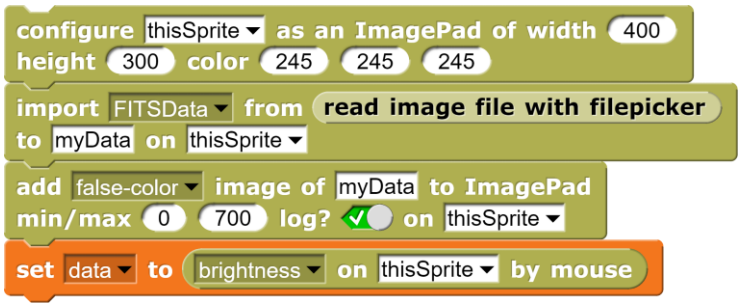

Wir erhalten die Gesamthelligkeit und die Zahl der gemessenen Pixel.

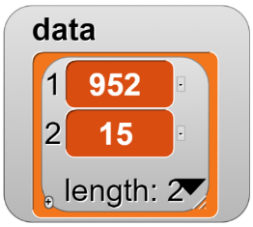

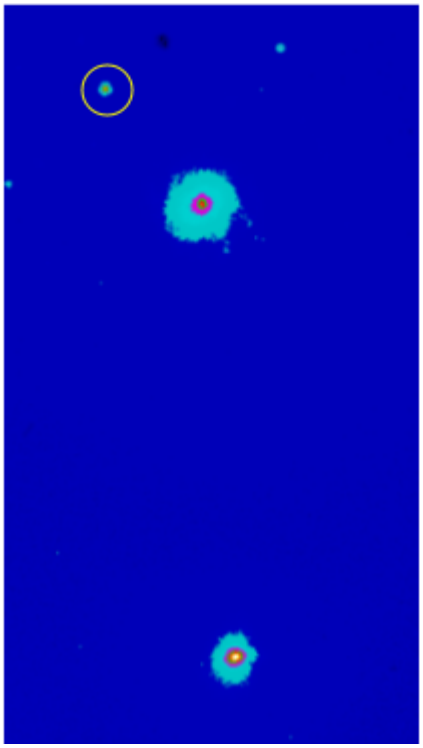

Der Export von Daten kann wiederum direkt aus einem Variablen-Watcher geschehen.

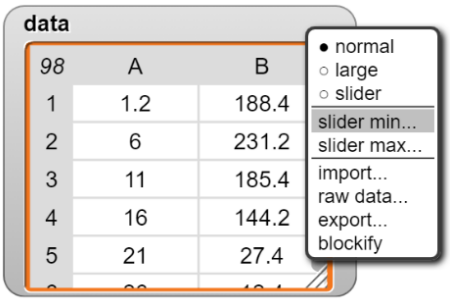

Für Skripte gibt es zwei neue Blöcke ***write <table> to CSV file <filename>*** sowie ***write string <string> to file <filename>***. Die Ergebnisse landen wie in *Snap!* üblich jeweils im Download-Ordner des Browsers. Die beiden Blöcke gestatten es, den Datenaustausch mit Tabellenkalkulationsprogrammen bzw. über Textdateien zu automatisieren, beispielsweise um Ergebnisse der Datenverarbeitung zu sichern.

5 Beispiele

5.1 Darstellung komplexer Zahlen

Die Operationen mit komplexen Zahlen können in *SciSnap!* leicht veranschaulicht werden, indem man das *MathPad* benutzt: eine Sprite-Konfiguration, mit der man schnell z. B. komplexe Zahlen als Pfeile darstellen kann. Da die komplexe Ebene zwei Dimensionen hat, müssen wir die Voreinstellung (3 Dimensionen) ändern, danach stellen wir zwei komplexe Zahlen und deren Summe verschiedenfarbig dar.

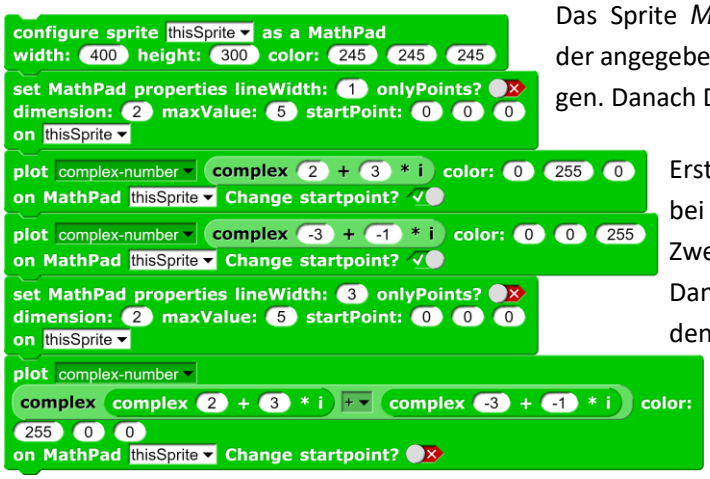

Das Sprite *MathSprite* als *MathPad* in der angegebenen Größe und Farbe erzeugen. Danach Dimension usw. einstellen.

Erste Zahl in Grün zeichnen, dabei Startpunkt verschieben.

Zweite Zahl in Blau zeichnen. Danach Startpunkt wieder in den Ursprung verschieben.

Die Summe in Rot vom Ursprung aus zeichnen.

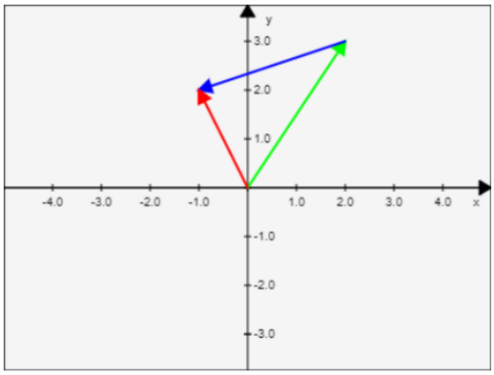

Da es sich um ein mathematisches Beispiel handelt, muss die Mitwirkung von *Hilberto* natürlich durch seine Mit-Darstellung angemessen gewürdigt werden.

5.2 Affine Transformation eines Dreiecks im R^2

Wir definieren ein Dreieck durch seine Ortsvektoren. Dann definieren wir drei Punkte in der Ebene sowie drei Punkte, auf die diese abgebildet werden sollen:

Danach erzeugen wir ein zweidimensionales *MathPad,* ändern den Maximalwert der Achsen und zeichnen das Dreieck in Rot. Auf seine Ortsvektoren wenden wir die affine Transformation an und zeichnen das Ergebnis in Blau. Da Koordinatentransformationen eher etwas für die Physik sind, stellt *Alberto* das Ergebnis vor.

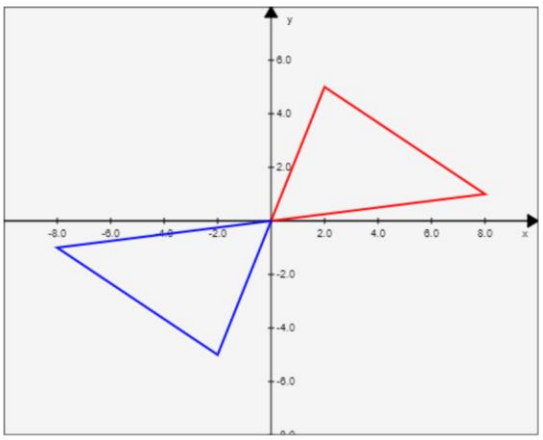

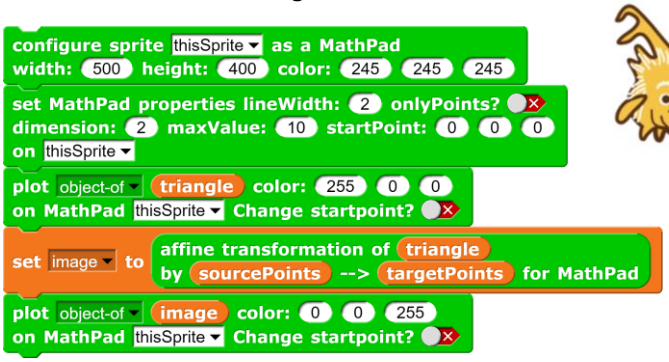

5.3 Drehung einer Pyramide im R^3

Zuerst wollen wir natürlich eine Pyramide zeichnen. Wir definieren die Grundfläche und die Spitze durch Ortsvektoren:

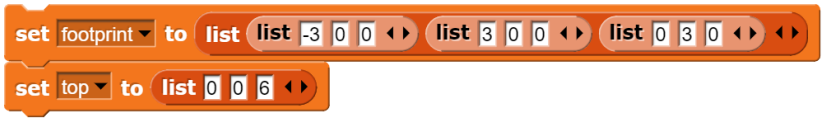

Wir lassen sie zeichnen, indem zuerst die Grundfläche gezeichnet wird, danach Linien von deren Ecken zur Spitze.

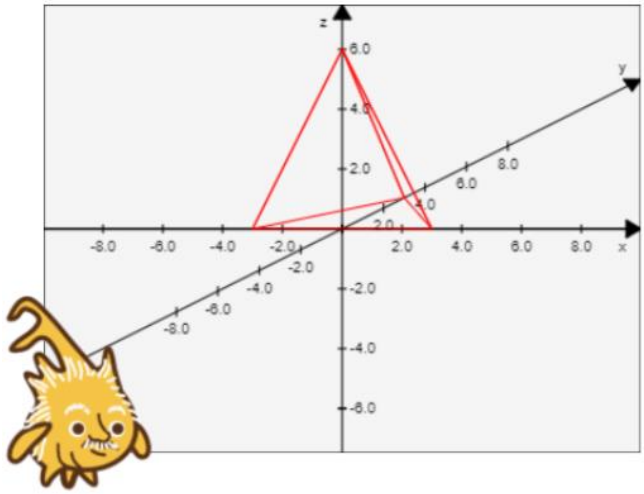

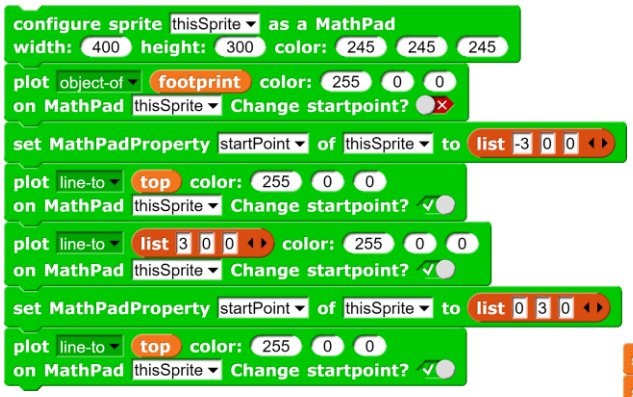

Für Drehungen um die Achsen benötigen wir die drei Drehmatritzen D_x, D_y und D_z. Für eine Drehung um die x-Achse um 90° können wir die Matrix direkt auf die Grundfläche anwenden. Danach lassen wir die Seitenlinien zur gedrehten Spitze zeichnen, indem wir die Drehmatrix mit den transponierten Ortsvektoren der Eckpunkte multiplizieren.

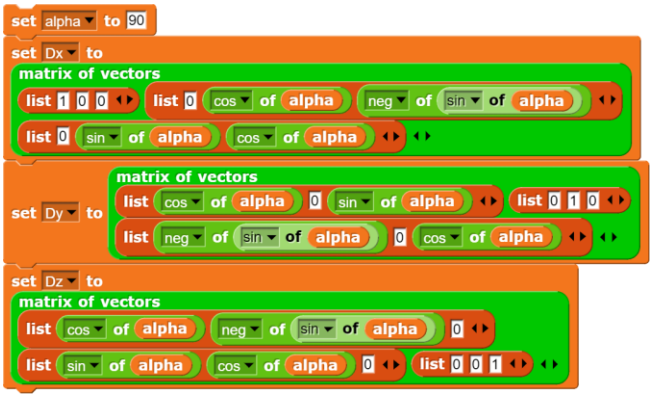

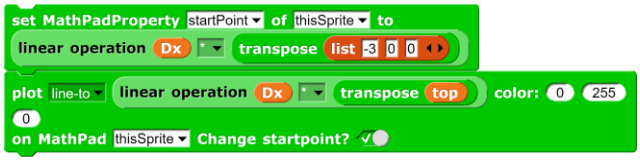

Insgesamt also:

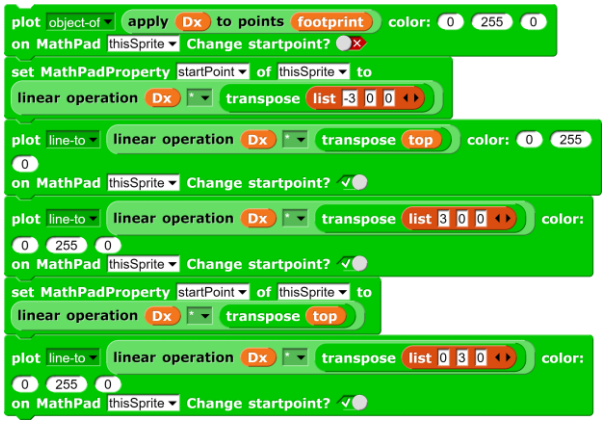

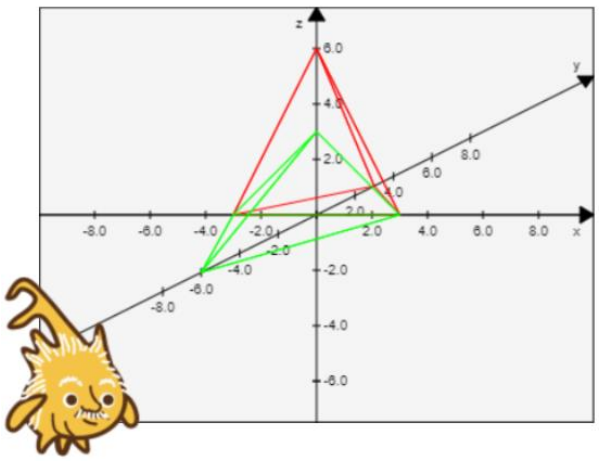

5.4 Graph der Normalverteilung

Mithilfe des *PlotPads* wird der Graph der Normalverteilung gezeichnet.

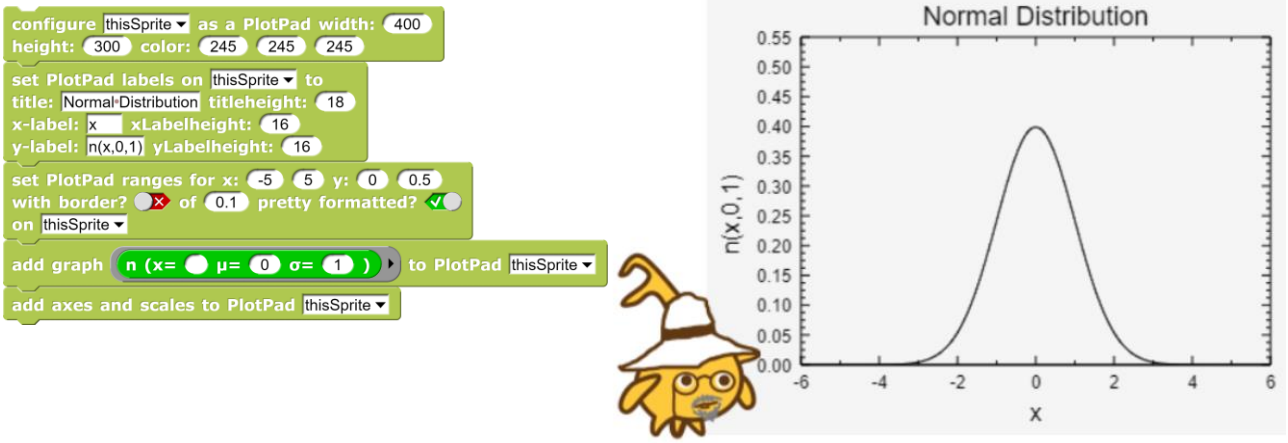

5.5 Kartesisches Produkt dreier Mengen

Zuerst einmal erzeugen wir drei Mengen mit Namen, möglichen Altern und Berufen:

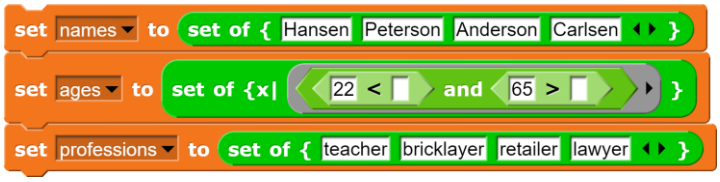

Dann erzeugen wir vier Werte aus dem „zugelassenen“ Altersbereich:

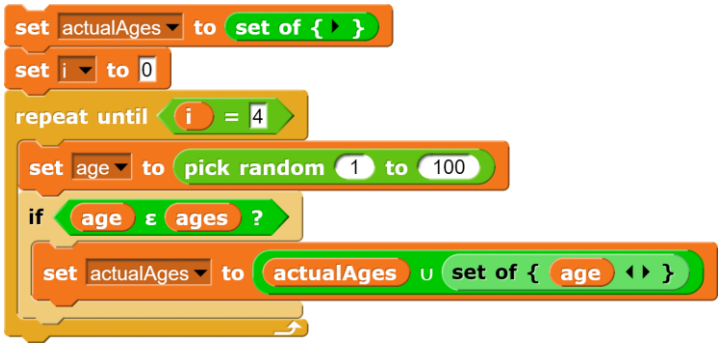

Aus diesen Mengen können wir nun das kartesische Produkt aus Namen, Alterswerten und Berufen bilden:

64	A	B	C
1	Peterson	64	bricklayer
2	Peterson	64	lawyer
3	Peterson	64	retailer
4	Peterson	64	teacher
5	Peterson	46	bricklayer
6	Peterson	46	lawyer
7	Peterson	46	retailer
8	Peterson	46	teacher
9	Peterson	44	bricklayer
10	Peterson	44	lawyer
11	Peterson	44	retailer
12	Peterson	44	teacher
13	Peterson	34	bricklayer

Und damit steht einem Übergang z. B. zum Thema „relationale Datenbanken“ nichts mehr im Wege.

5.6 Darstellung einer Punktmenge und der Regressionsgeraden

Wir erzeugen mithilfe der *SciSnap!DataLibrary* 100 Zufallspunkte, die um eine Gerade mit der Steigung *m=0.5* und dem Achsenabschnitt *b=0* streuen. Die erhaltenen Punkte stellen wir in einem Diagramm dar.

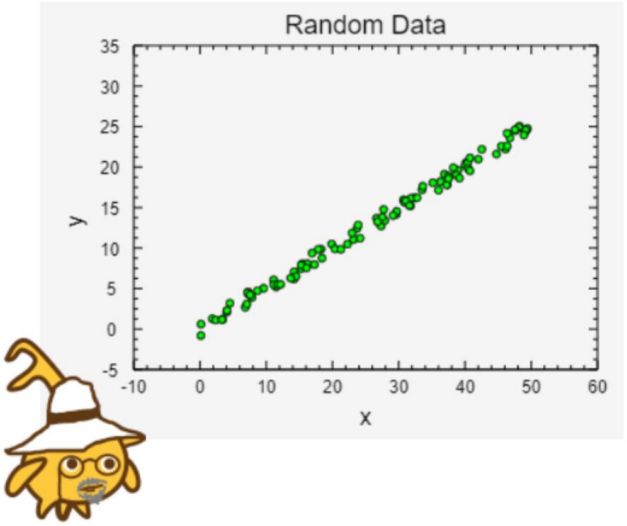

Zusätzlich wird jetzt noch die Regressionsgerade eingezeichnet.

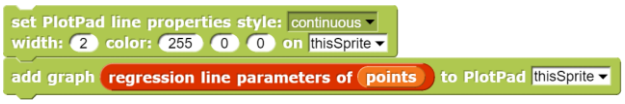

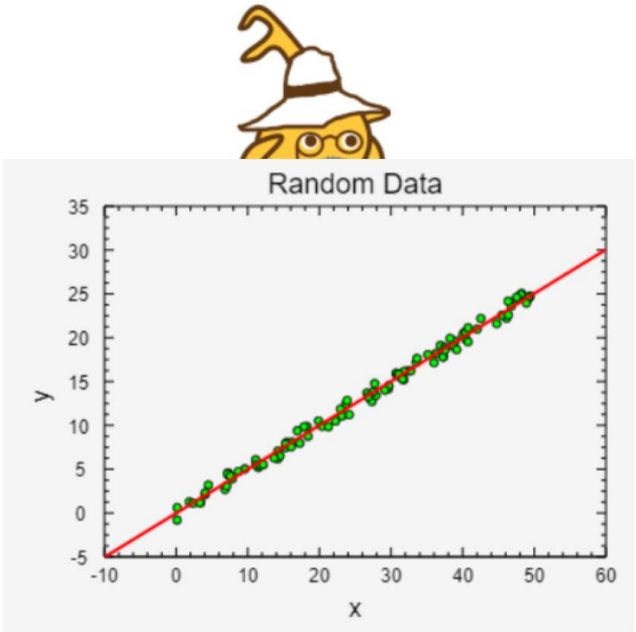

5.7 Interpolationspolynom durch n Punkte

Wir wollen eine Datenmenge von 100 Punkten erzeugen, die um eine vorgegebene Funktion streuen. Diese Punkte stellen wir in einem Diagramm dar. Anschließend wählen wir drei Punkte aus, indem wir mit der Maus die entsprechenden Orte anklicken und dort eine rote Markierung setzen. Durch dieses drei Punkte zeichnen wir anschließend ein Interpolationspolynom in Rot. Da es sich um ein „mathematisches“ Projekt handelt, ist *Hilberto* dafür zuständig.

Zuerst einmal die Zufallspunkte:

Danach konfigurieren wir das aktuelle Sprite zum *PlotPad* und zeichnen die Punktmenge.

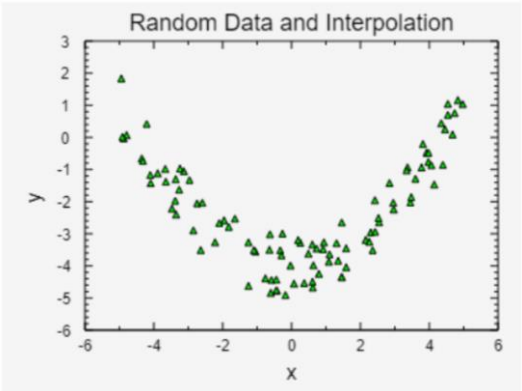

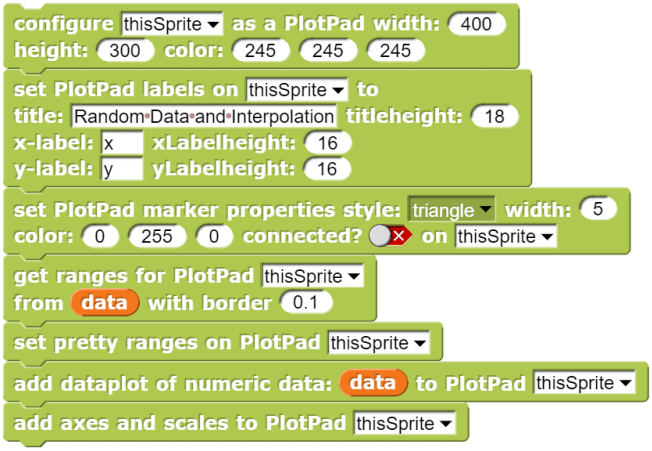

Jetzt wählen wir die drei Punkte und stellen sie gleich im Diagramm dar.

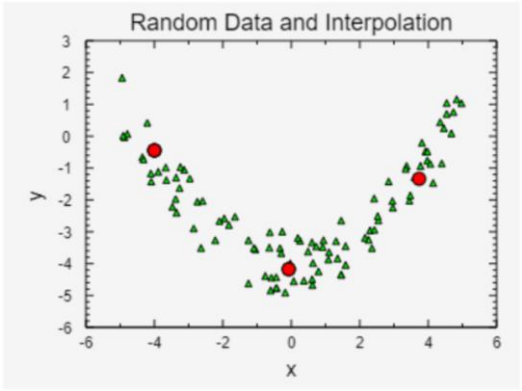

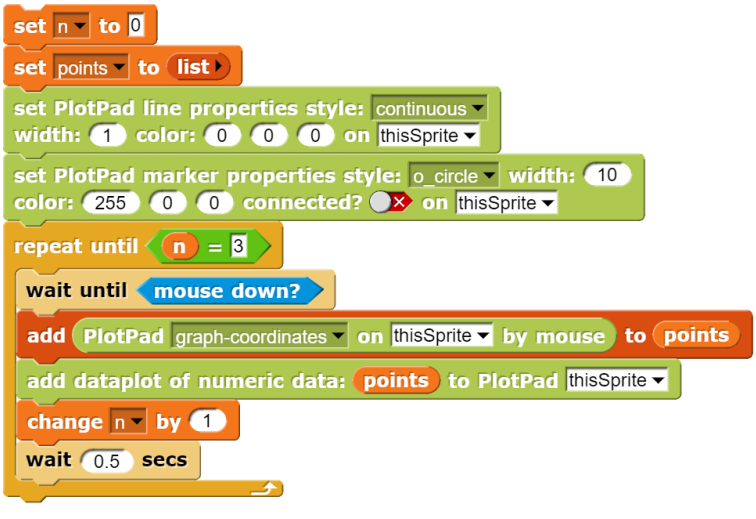

Und zuletzt fügen wir das Interpolationspolynom hinzu.

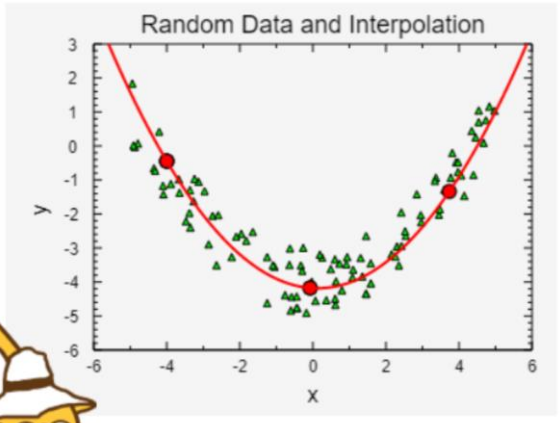

Aufgaben:

1. a: Erzeugen Sie „Punktwolken“, die um andere ganzrationale Funktionsgraphen streuen.

   b: Legen Sie wie im Beispiel einige Punkte in diesen Wolken fest, durch die ein Interpolationspolynom gezeichnet werden soll.

   c: Lassen Sie diese Polynome zeichnen.

2. a: Experimentieren Sie mit der Anzahl der ausgewählten Punkte. Werden die Ergebnisse besser, wenn Sie mehr Punkte wählen?

   b: Erzeugen Sie „Punktwolken“, die um nicht ganzrationale Funktionsgraphen (trigonometrische, …) streuen. Können Sie auch diese durch Interpolationspolynome beschreiben?

   c: Formulieren Sie eine Regel, wann und wie man Interpolationspolynome sinnvoll einsetzen kann - und weshalb gerade so.

5.8 Approximation einer Tangente durch Sekanten

Wir wollen zeigen, dass eine Folge von Sekantensteigungen gegen die Steigung der Tangente in einem Punkt konvergiert. Dazu konfigurieren wir ein Sprite namens *PlotPad* als *PlotPad* und zeichnen den Graph einer Funktion, hier: $y = 0{,}3 \cdot x^3 - 3 \cdot x$.

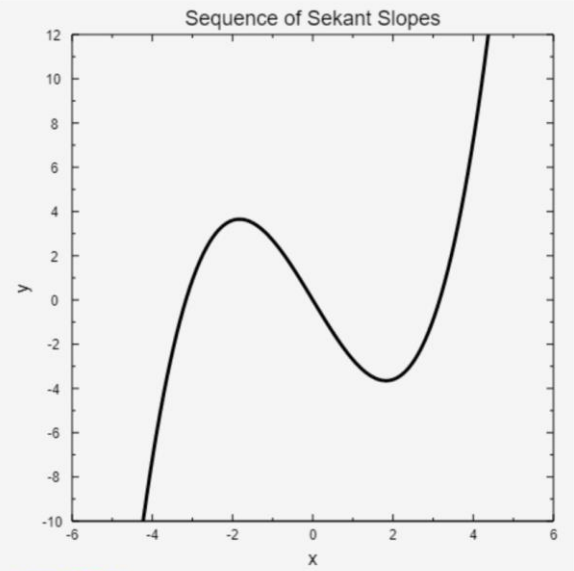

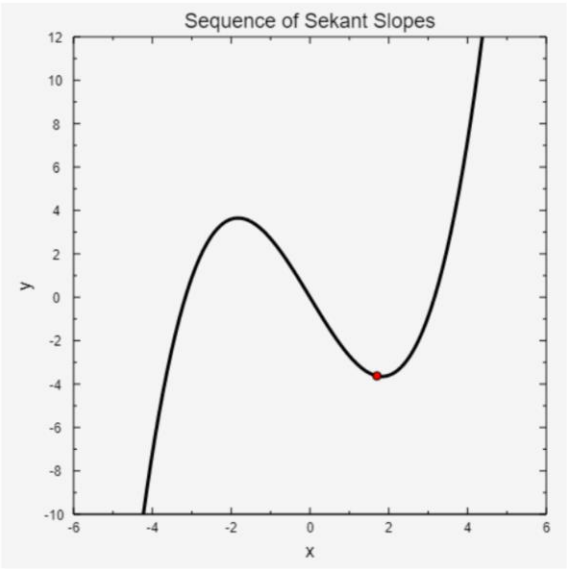

Der Rest ist genauso einfach: wir lassen die Sekantensteigungen berechnen …

… und die Sekanten in Farbabstufungen zeichnen.

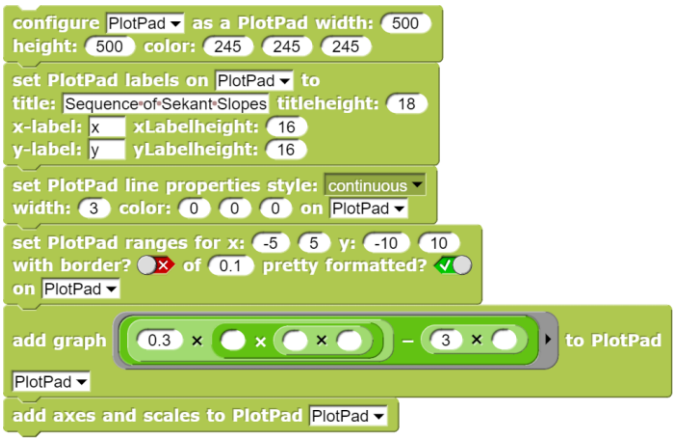

Wir wollen in der Nähe des rechten Minimums eine Folge von Sekanten zeichnen lassen, die sich der Tangente nähern. Dafür benötigen wir natürlich erstmal einen Punkt $(x_0 | y_0)$ in der Nähe des Minimums:

Den können wir auch gleich einzeichnen.

Als Folge zur Annäherung an den Punkt wählen wir $a_n = \frac{2}{n}$. Von der lassen wir die ersten 20 Glieder erzeugen.

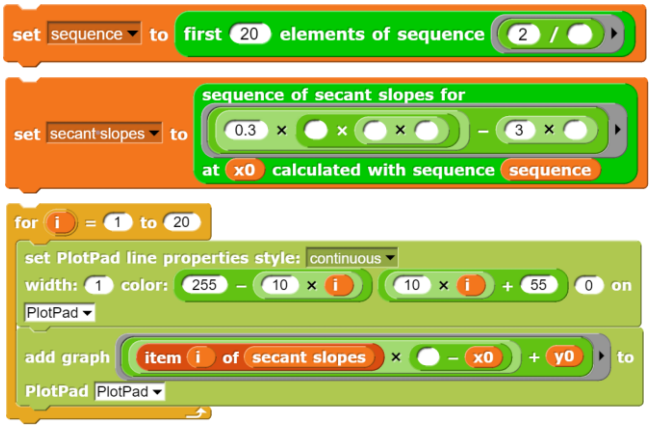

Das Ganze – mit Ergebnis – noch einmal in einem Stück:

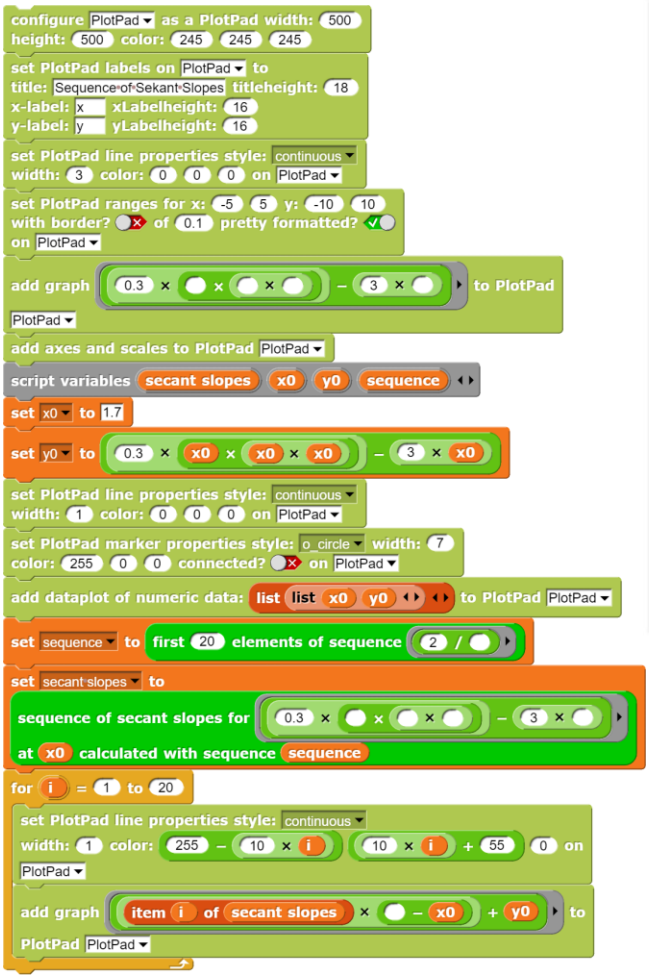

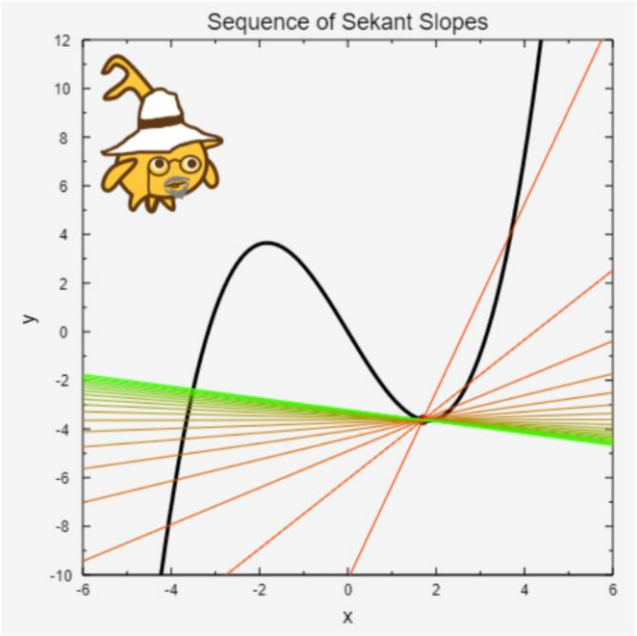

Aufgaben:

1. Lassen Sie zusätzlich die „richtige“ Tangente in das Diagramm einzeichnen.
2. Wählen Sie als Folge für die Sekantenberechnung andere Folgen, die sich dem Punkt $(x_0|y_0)$ von der anderen bzw. beiden Seiten nähern.
3. a: Veranschaulichen Sie auf ähnliche Weise die Nullstellenberechnung nach dem Newton-Verfahren.

   b: Wählen Sie einige Fälle, in denen das Verfahren gut funktioniert bzw. kaum noch oder gar nicht.

5.9 Endliche Reihen

Wir wollen einige der üblichen mathematischen Konstanten und Funktionen über Reihenentwicklungen annähern – und auch mal ausprobieren, wie lange man eigentlich rechnen muss, um gute Ergebnisse zu erhalten.

Beginnen wir einmal mit π. In einer Formelsammlung[19] oder bei Wikipedia[20] finden wir eine Formel zur Berechnung von π: die *Leibniz-Reihe*: $\frac{\pi}{4} = \sum_{i=0}^{n} \frac{(-1)^i}{(2 \cdot i+1)}$

Die können wir direkt in *SciSnap!* umsetzen.

Aber wann ist das Ergebnis eigentlich „gut“?

Zur Beantwortung dieser Frage erstellen wir eine Tabelle.

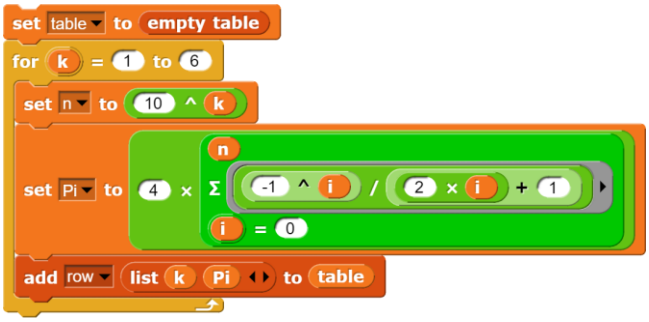

Bei 10 Millionen Summanden muss man schon etwas auf das Ergebnis warten! 😉

table

	A	B
1	10	3.232315809405594
2	100	3.1514934010709914
3	1000	3.1425916543395442
4	10000	3.1416926435905346
5	100000	3.1416026534897203
6	1000000	3.1415936535887745
7	10000000	3.1415927535897814

Eigentlich ist es doch seltsam, dass man für so wenig verbesserte Genauigkeit so lange rechnen muss. So etwas kann man vielleicht im Jahre 1673 im verregneten Hannover machen, um nicht spazieren gehen zu müssen – aber jetzt? Wir versuchen es einfach mal mit der *BIGNUM*-Library von *Snap!* für exakte Rechnungen mit *Scheme*-Zahlen. Dann dauert das Rechnen noch länger und wir erhalten erstaunliche Ergebnisse, die nicht nach π aussehen.

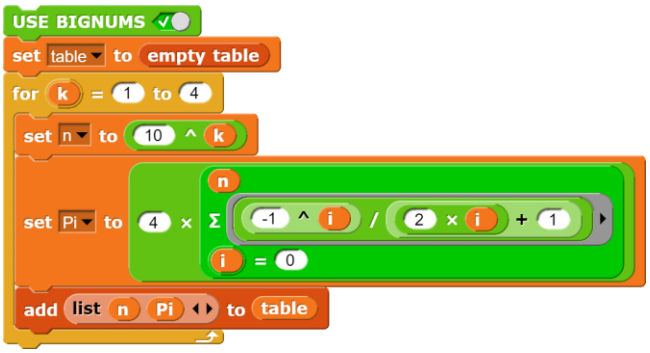

table

	A	B
1	10	47028692/14549535
2	100	830451968305093031586835172847858137121823705761010747562787642768870056465870233156058826351061627572364
3	1000	463771016605518999270845997524183318155107079951977133705996697620791437153292540061321203648540283671267

Nach langem Suchen entdecken wir den Bruchstrich in der Mitte, wobei der schon in der zweiten Zeile nicht mehr zu sehen ist. *Scheme*-Zahlen sind nun mal exakte Brüche und keine Gleitkommazahlen.

[19] Fragen Sie mal ihren Opa, was das ist. 😉
[20] https://de.wikipedia.org/wiki/Leibniz-Reihe

Wir lassen deshalb die exakten *Scheme*-Zahlen in die inexakte Gleitkomma-Darstellung umwandeln, bevor wir sie in die Tabelle eintragen.

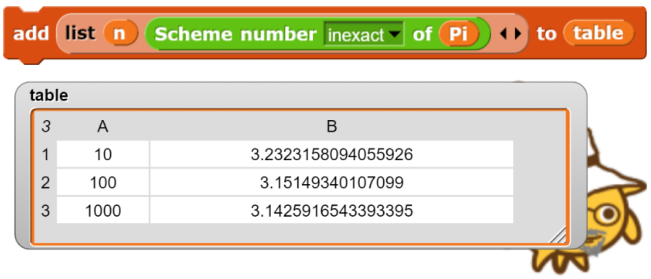

Trotz des Aufwands sind die Ergebnisse fast die gleichen wie vorher. Das schlechte Konvergenz-Verhalten der Reihe liegt also nicht an den Ungenauigkeiten der Standard-Arithmetik einer Programmiersprache (hier: *JavaScript*), sondern an ihrem Aufbau. Gut zu wissen! 😉

Aufgaben:

1. Informieren Sie sich über die Bedeutung der Begriffe „*Scheme-Zahlen*“ und „*Gleitpunkt-zahlen*“.
2. Suchen Sie sich andere Reihenentwicklungen für π, die besser konvergieren als die Leibniz-Reihe.
3. Suchen und implementieren Sie eine Reihenentwicklung für die Eulersche-Zahl e.
4. Informieren Sie sich über Gründe, mit der Genauigkeit von Scheme-Zahlen zu rechnen, statt der für Gleitpunktzahlen.
5. Schreiben Sie Skripte für die Reihenentwicklung trigonometrischer Funktionen, z. B. *sin(x)*, *cos(x)*, … Beachten Sie, dass dabei der Winkel im Bogenmaß angegeben werden muss.

5.10 Anwendung der Taylor-Reihe beim mathematischen Pendel

Eine sehr anschauliche Anwendung von Reihenentwicklungen ist die Simulation eines mathematischen Pendels, also eines Fadenpendels. Üblicherweise arbeitet man dort mit der Näherung, dass für kleine Winkel der Wert des Sinus (im Bogenmaß) in etwa dem Wert seines Arguments entspricht – d. h. man bricht die Reihenentwicklung der Sinusfunktion nach dem ersten Summanden ab. Wir sehen uns das mal genauer an: Die Kraft F, die die Kugel auf der Kreisbahn beschleunigt, erhalten wir vom Betrag her als $F = -G \cdot \sin\varphi = -m \cdot g \cdot \sin\varphi$. Nach der Grundgleichung der Mechanik ist diese Kraft gleich der Trägheitskraft $m \cdot \ddot{s} = m \cdot a$. Benutzen wir die Beziehung für den Winkel im Bogenmaß $\varphi = \frac{s}{L}$, dann erhalten wir

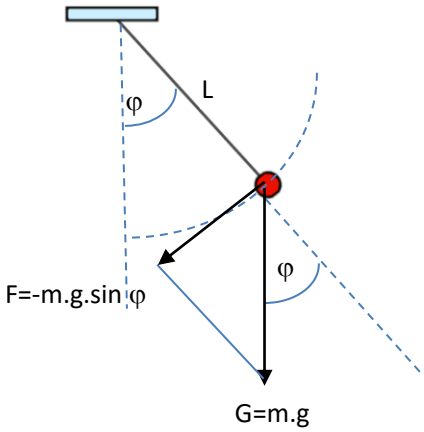

$$\ddot{\varphi} = -\frac{g}{L} \cdot \sin\varphi$$

Für kleine Winkel gilt genähert $\sin\varphi \approx \varphi$ und damit

$$\ddot{\varphi} \approx -\frac{g}{L} \cdot \varphi$$

Mal sehen, ob das funktioniert! Wir simulieren zuerst einmal die „echte“ Pendelbewegung, indem wir die Beschleunigung aus der aktuellen Situaltion entnehmen, daraus die Änderung der Gewschwindigkeit bestimmen und daraus wiederum die neue Position. Die Daten nehmen wir in eine Liste *plotdata1* auf. Einige weitere Größen wie die Pendellänge und die Anfangsauslenkung geben wir über Variable in der Slider-Darstellung vor. Zuerst einmal zeichnen wir die Anfangssituation: Ein Stift zeichnet erforderliche Linien, und das Pendel hängt natürlich an der Decke des Labors.

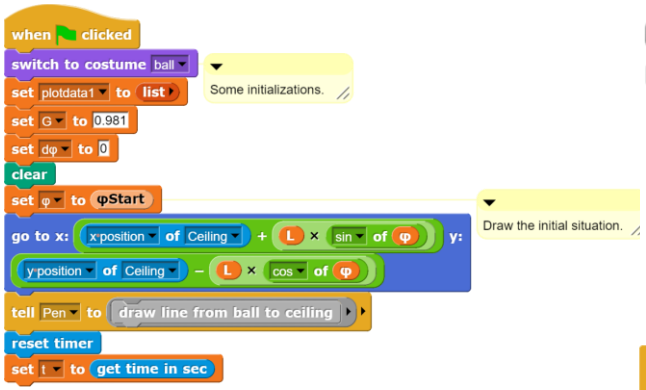

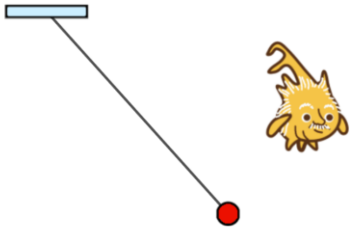

Jetzt geht es los: Wir messen die aktuelle Auslenkung und die Zeit und schreiben beide Werte in die Liste der Messwerte. Danach berechnen wir die aktuelle Beschleunigung, die die Winkelgeschwindigkeit ändert, und daraus den neuen Winkel. Dann lassen wir die neue Situation zeichnen. Und das immer wieder.

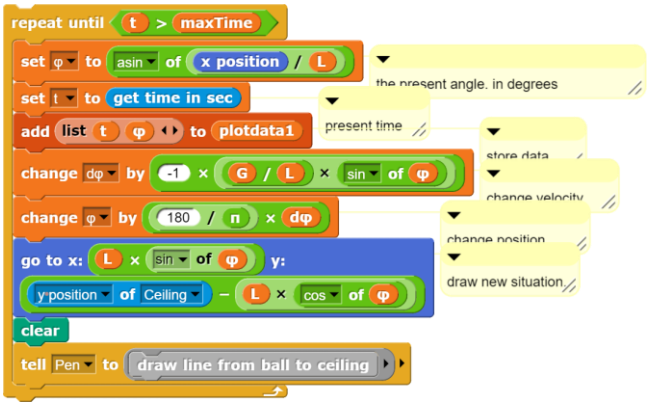

Dieser Anordnung spedieren wir ein weiteres Sprite als PlotPad: den *Plotter*. Der ist schnell genug, die aktuellen Daten in Echtzeit darzustellen. Deshalb fügen wir den Block dafür in die Simulationsschleife des Pendels ein.

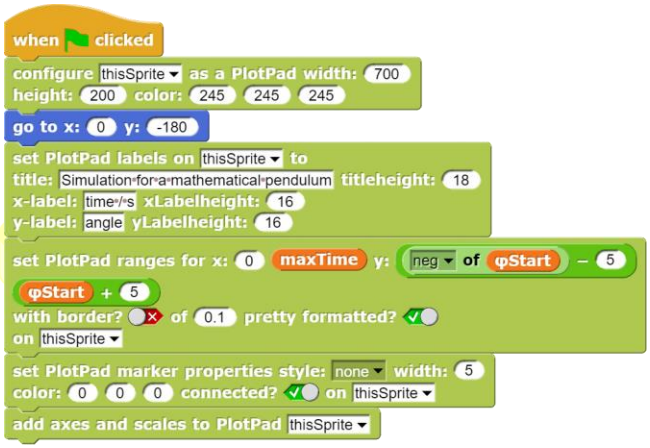

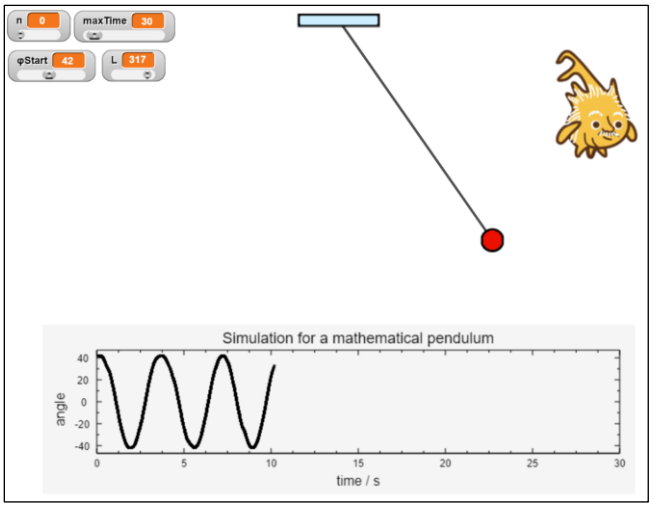

Alberto ist sichbar begeistert, dass das so gut klappt!

Das eigentliche Ziel war es aber, sich mal anzusehen, wie gut die Näherung ist. Dafür führen wir eine zweite Datenliste *plotdata2* ein sowie einen „genäherten“ Winkel $\varphi Approx$ und die entsprechende Winkelgeschwindigkeit. Der „echte“ Winkel φ und der genäherte starten mit dem gleichen Wert. Danach wird jeweils die „echte“ Auslenkung des Pendels gemessen und der genäherte Wert berechnet. Beides zeichnen wir in das Diagramm ein – den berechneten Wert in Rot.

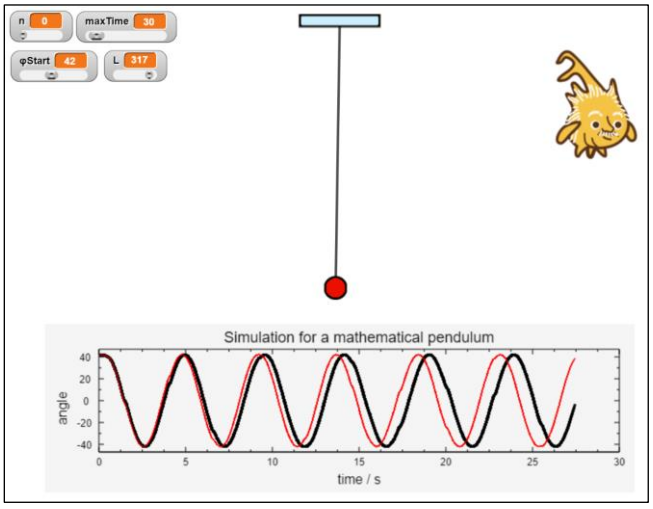

Man sieht, dass die Näherung anfangs ganz gut ist, aber mit zunehmender Zeit mit den Echtzeitwerten auseinander läuft.

Das kann man besser machen!

Statt der linearen Näherung wählen wir die Taylorreihe des Sinus, von der wir *n* Summanden als Näherung verwenden. *n* geben wir als Slider-Variable vor.

$$\sin\varphi = \sum_{i=0}^{n} (-1)^i \cdot \frac{\varphi^{2i+1}}{(2i+1)!} = \varphi - \frac{\varphi^3}{3!} + \frac{\varphi^5}{5!} - \cdots$$

Das können wir direkt in *SciSnap!* abschreiben:

Zusammen mit der Umrechnung von Winkeln ins Bogenmaß erhalten wir für die Winkelbeschleunigung:

Schon bei einer Erweiterung der Näherung um ein Reihenglied (also $-\frac{\varphi^3}{3!}$) sind die Abweichung von den Messwerten im Diagramm nicht mehr sichtbar.

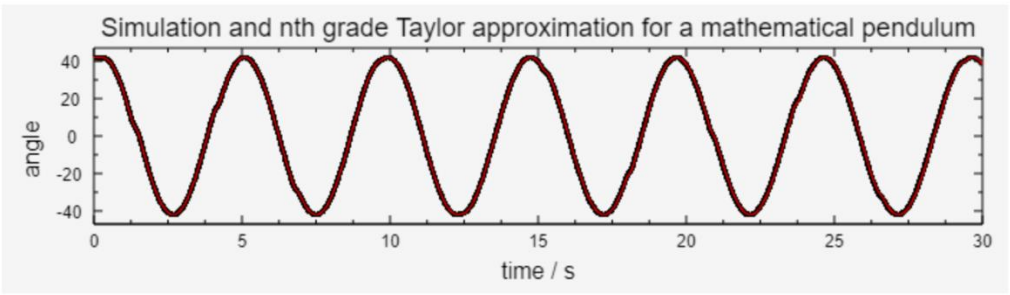

Aufgaben:

1. Lassen Sie die Simulation länger laufen und stellen Sie fest, wann sich – in Abhängigkeit von der Zahl der Summanden der Taylorreihe – Abweichungen zeigen.
2. Machen Sie das Gleiche für unterschiedliche Startwinkel des Pendels.

5.11 Fourier-Entwicklung für ein Rechtecksignal mit numerischer Integration

Eine Möglichkeit zur Fourier-Darstellung einer 2π-periodischen Funktion $f(x)$ ist

$$f(x) \cong a_0 + \sum_{k=1}^{\infty} (a_k \cdot \cos(k \cdot x) + b_k \cdot \sin(k \cdot x)) \qquad a_0 = \frac{1}{2\pi} \cdot \int_0^{2\pi} f(x) \cdot dx$$

$$a_k = \frac{1}{\pi} \cdot \int_0^{2\pi} f(x) \cdot \cos(k \cdot x) \cdot dx \qquad b_k = \frac{1}{\pi} \cdot \int_0^{2\pi} f(x) \cdot \sin(k \cdot x) \cdot dx\,;\ k = 1,2,3,\ldots$$

Wir wollen die Koeffizienten für die Reihenentwicklung eines Rechtecksignals rein numerisch ermitteln und dabei testen, wie sich die Länge der Reihenentwicklung auf die Genauigkeit der Ergebnisse auswirkt.

Zuerst einmal benötigen wir ein Rechtecksignal mit der Periode 2π. Eine Funktion, die das liefert, wäre z. B. $f(x) = \begin{cases} -1 & falls\ (x\ mod\ 2\pi - \pi) > 0 \\ 1 & falls\ (x\ mod\ 2\pi - \pi) < 0 \\ 0 & sonst \end{cases}$

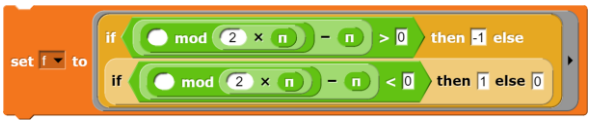

Das sehen wir uns natürlich erst einmal im Diagramm an, bevor wir glauben, dass es sich um ein Rechtecksignal handelt:

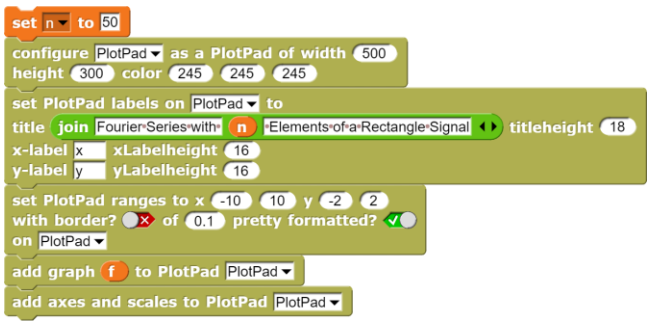

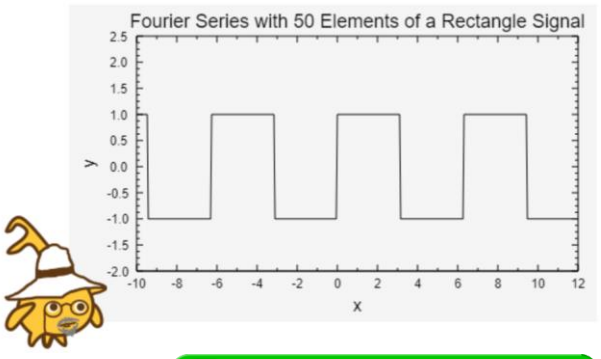

Stimmt also. 😉

Jetzt müssen wir für jeden Wert von *x* die ersten *n* Koeffizienten der Fourier-Reihe berechnen. Dafür benutzen wir den Block für die numerische Integration.

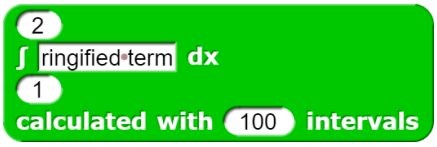

Probieren wir es also mal für $a_0 = \frac{1}{2\pi} \cdot \int_0^{2\pi} f(x) \cdot dx$.
Da wir den „ringified term“ für die Funktion *f* schon haben, können wir einfach abschreiben:

Bei den anderen Koeffizienten müssen wir die trigonometrischen Terme ergänzen und erhalten für

a_k:

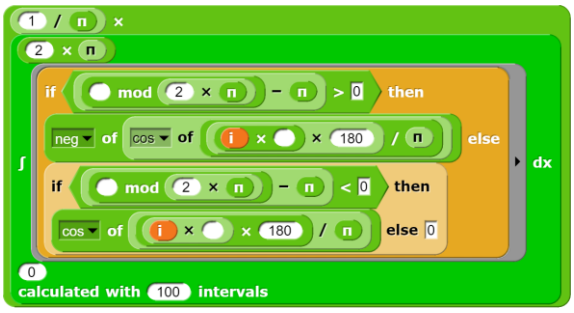

und b_k:

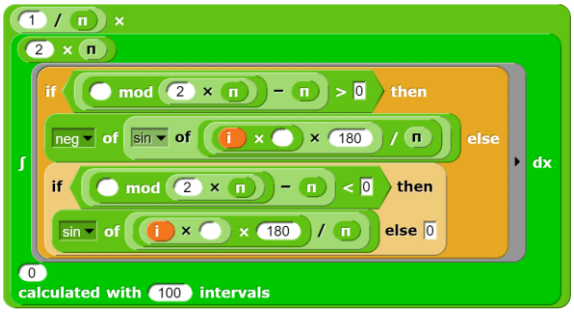

Diese Terme müssen jetzt nur noch summiert werden:

Damit erhalten wird insgesamt das folgende Skript.

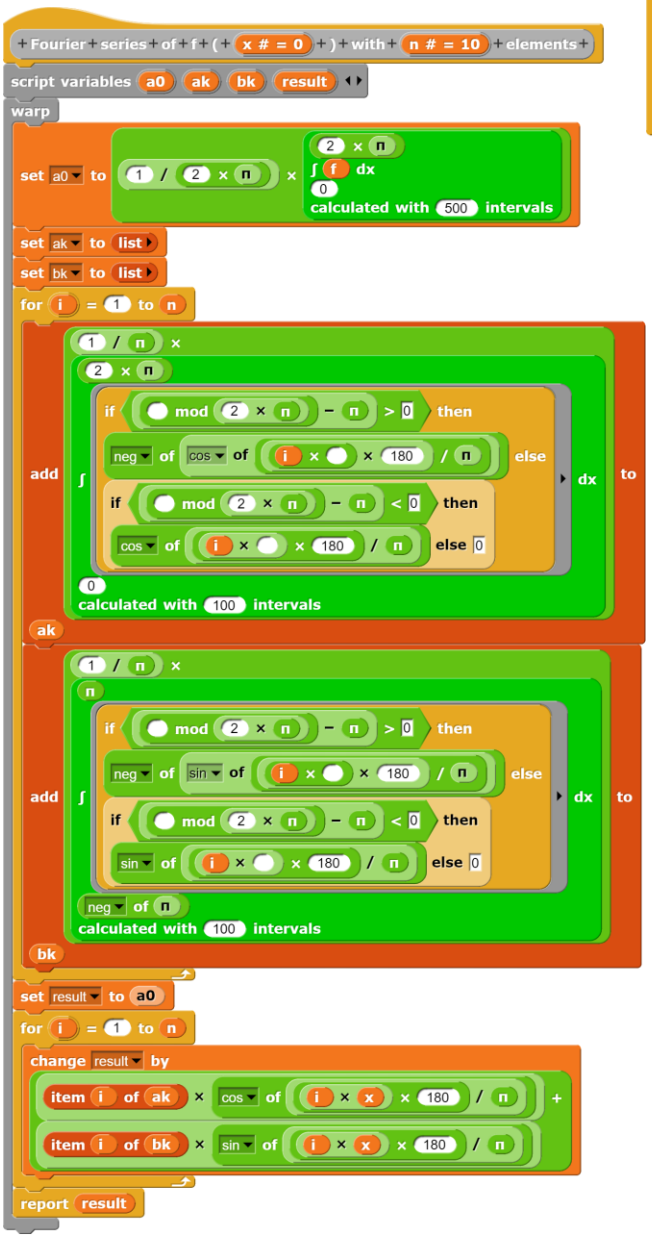

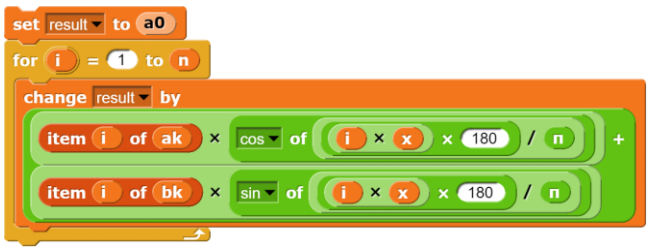

Wie haben darin zwei „Schrauben“, an denen wir drehen können: einerseits kann die Zahl *n* der Terme der Fourier-Reihe geändert werden, andererseits die Anzahl *i* der Intervalle bei der numerischen Integration. Die Auswirkungen von Änderungen lassen sich leicht beurteilen, wenn wir zufällig Werte aus dem Wertebereich von *x* ziehen und das Ergebnis zusammen mit der Funktion *f* plotten lassen. Abweichungen zeigen sich dann sofort.

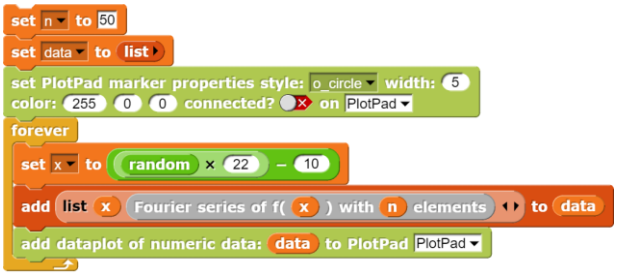

n Summanden	i Intervalle	Ergebnis	Kommentar
50	100	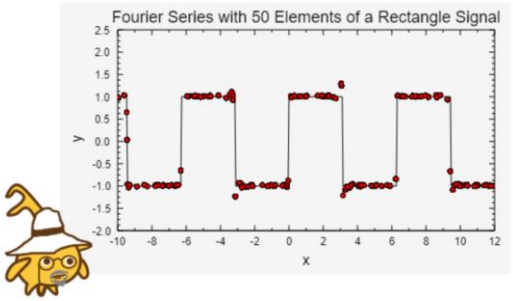	Eigentlich ganz gut bis auf „Ausrutscher“, die an den Sprungstellen der Funktion liegen.

50	50	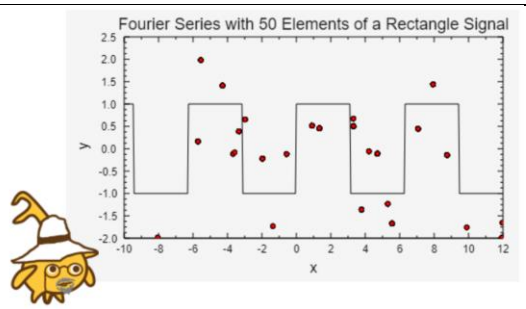	Das dürfte eindeutig sein.
50	200	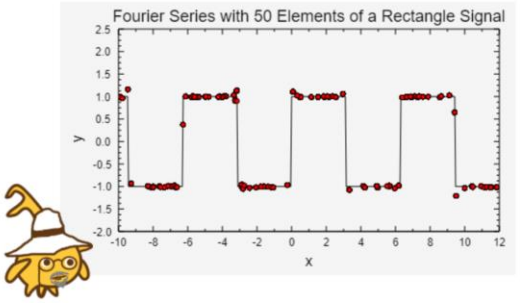	Besser, aber nur wenig besser als mit 100 Summanden.
25	200	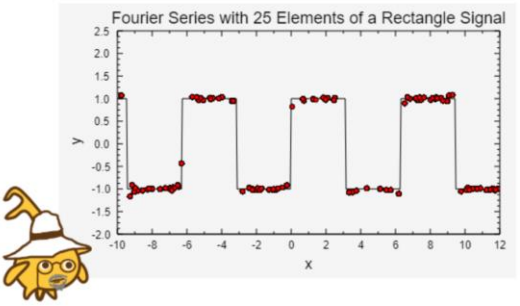	Schlechter, aber nur unwesentlich schlechter als mit 50 Summanden.
10	100	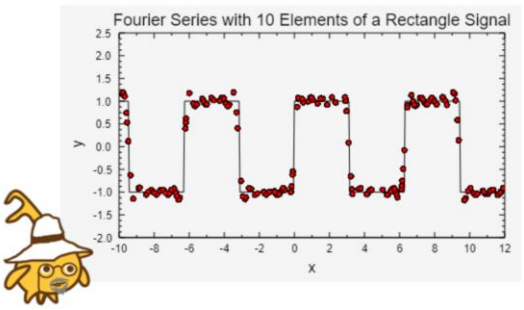	Vielleicht ein ganz guter Kompromiss zwischen Genauigkeit und Rechenzeitbedarf.
5	75	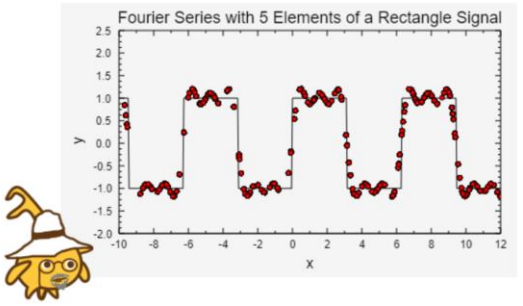	In vielen Fällen wohl auch noch vertretbar.

Man sieht, dass es wohl von der Aufgabenstellung abhängt, welche Genauigkeit benötigt wird. Sind z. B. Ausrutscher an den Sprungstellen vertretbar oder kommt es gerade da auf Präzision an? Man sieht auch, dass man mit gleichem Aufwand sehr unterschiedliche Wirkungen erzielen kann.

Aufgaben:

1. a: Geben Sie Funktionsterme für ein Dreieckssignal, ein Signal aus Peaks, … an. Lassen Sie die Funktionsgraphen zeichnen.

   b: Berechnen Sie die Fourierreihen für die Signale.

   c: Experimentieren Sie wie gezeigt, um einen vertretbaren Kompromiss zwischen Genauigkeit und Rechenzeitbedarf zu finden.

2. a: Erzeugen Sie Tabellen mit den Daten für ein Dreieckssignal, ein Signal aus Peaks, … mithilfe der Funktionsterme.

   b: Geben Sie die Signale über den Lautsprecher aus.

   c: Erzeugen Sie die entsprechenden Tabellen mithilfe unterschiedlich guter Fourier-Reihen und hören Sie sich auch diese als Töne an. Nehmen Sie Unterschiede wahr?

3. Informieren Sie sich über Einsatzgebiete von Fourier-Reihen.

5.12 NY CitiBike Tripdata 1: Korrelationen

Als Beispiel für die Anwendung der Blöcke wollen wir etwas in einer größeren, frei verfügbaren Datenmenge „wühlen“: den Entleihdaten von New York Citi Bike (NY citibike tripdata: https://www.citibikenyc.com/system-data).

Wir laden die Daten, entpacken sie und erhalten CSV-Daten ziemlicher Größe, die wir „auf einen Schlag“ in den Datenbereich von *SciSnap!*, die Variable *SciSnap!Data*, laden. Wir erhalten knapp 600.000 Datensätze.

DataSprite myData

577704	A	B	C	D	E	F	G	H	I	J
1	tripduration	starttime	stoptime	start station	start station	start station	start station	end station	end station	end station
2	695	2013-06-01	2013-06-01	444	Broadway &	40.7423543	-73.9891507	434	9 Ave & W 1	40.7431744
3	693	2013-06-01	2013-06-01	444	Broadway &	40.7423543	-73.9891507	434	9 Ave & W 1	40.7431744
4	2059	2013-06-01	2013-06-01	406	Hicks St & M	40.6951284	-73.9959506	406	Hicks St & M	40.6951284
5	123	2013-06-01	2013-06-01	475	E 15 St & Irv	40.7352427	-73.9875856	262	Washington	40.6917823
6	1521	2013-06-01	2013-06-01	2008	Little West S	40.7056925	-74.0167768	310	State St & Si	40.6892694
7	2028	2013-06-01	2013-06-01	485	W 37 St & 5	40.7503800	-73.9833898	406	Hicks St & M	40.6951284
8	2057	2013-06-01	2013-06-01	285	Broadway &	40.7345456	-73.9907414	532	S 5 Pl & S 5	40.710451
9	369	2013-06-01	2013-06-01	509	9 Ave & W 2	40.7454973	-74.0019713	521	8 Ave & W 3	40.7509673
10	1829	2013-06-01	2013-06-01	265	Stanton St &	40.7222934	-73.9914753	436	Hancock St	40.6821656
11	829	2013-06-01	2013-06-01	404	9 Ave & W 1	40.7405826	-74.0055086	303	Mercer St &	40.7236273
12	1316	2013-06-01	2013-06-01	423	W 54 St & 9	40.7658494	-73.9869050	314	Cadman Pla	40.69383
13	1456	2013-06-01	2013-06-01	502	Henry St & C	40.714215	-73.981346	532	S 5 Pl & S 5	40.710451
14	386	2013-06-01	2013-06-01	241	DeKalb Ave	40.6898103	-73.9749312	365	Fulton St &	40.6822316
15	924	2013-06-01	2013-06-01	486	Broadway &	40.7462009	-73.9885572	521	8 Ave & W 3	40.7509673
16	1233	2013-06-01	2013-06-01	527	E 33 St & 2 /	40.744023	-73.976056	296	Division St &	40.7141308
17	512	2013-06-01	2013-06-01	309	Murray St &	40.7149787	-74.013012	300	Shevchenko	40.728145
							-74.013012	347	Greenwich S	40.728846

Deren Spaltenüberschriften spalten wir von der Tabelle ab.

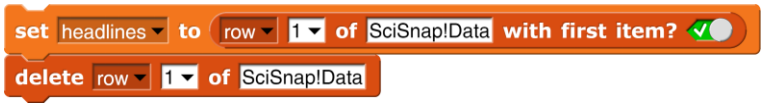

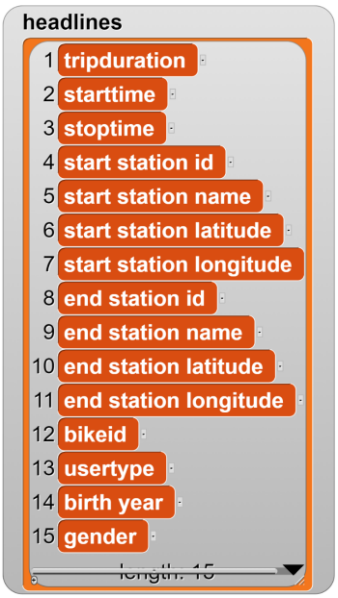

Diese Daten lassen sich in sehr unterschiedlicher Art auswerten. Wir werden das später auch noch tun, beschränken uns aber erst einmal auf die Frage, ob es eine Korrelation zwischen Geschlecht und Ausleihdauer gibt. Dafür benötigen wir offensichtlich nur die Spalten 1 und 15. Wir löschen deshalb die anderen Spalten.

SciSnap!Data

577703	A	B
1	695	1
2	693	1
3	2059	0
4	123	1
5	1521	1
6	2028	0
7	2057	1
8	369	1
9	1829	1
10	829	1

Zuerst einmal sehen wir uns die Mittelwerte für die unterschiedlichen Geschlechter an (0: unbekannt, 1 männlich, 2: weiblich):

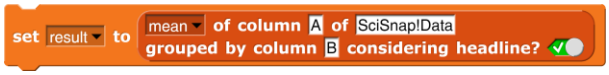

result

4	1	B
1	value	mean
2	0	1753.2988186
3	1	1063.5487225
4	2	1233.2494452

Das haben wir uns doch gedacht! 😉

Und wie sieht es nun mit der Korrelation aus? Wir werfen zuerst die Daten mit dem „unbekannten“ Geschlecht raus. Es bleiben immer noch ca. 340.000 Datensätze. Für diese berechnen wir den Korrelationskoeffizienten zwischen Spalte 1 und 2 – und erhalten das nebenstehende Resultat.

Und was will uns diese Zahl nun sagen??? Wir wissen es nicht – aber wir können ja nachlesen und es lernen! 😉

5.13 Einkommensdaten aus dem US Census Income Dataset (Quelle: [Census])

Wir wollen etwas in Daten wühlen und laden uns deshalb den *Census Income Dataset* aus dem Netz.[21] Die entsprechende CSV-Datei lässt sich aus dem Dateiverzeichnis in ***SciSnap!Data*** laden und sofort anzeigen. Sie umfasst 32562 Datensätze. Ein Doppelklick oder ein Rechtsklick darauf und die Wahl von *„open in dialog…“* zeigt alle Spalten.

32562	A	B	C	D	E	F	G	H	I	J	K	L	M
1	age	workclass	final weight	education	education-n	marital-statu	occupation	relationship	race	sex	capital-gain	capital-loss	hours-per-v
2	39	State-gov	77516	Bachelors	13	Never-marri	Adm-clerica	Not-in-famil	White	Male	2174	0	40
3	50	Self-emp-nc	83311	Bachelors	13	Married-civ-	Exec-manag	Husband	White	Male	0	0	13
4	38	Private	215646	HS-grad	9	Divorced	Handlers-cl	Not-in-famil	White	Male	0	0	40
5	53	Private	234721	11th	7	Married-civ-	Handlers-cl	Husband	Black	Male	0	0	40
6	28	Private	338409	Bachelors	13	Married-civ-	Prof-special	Wife	Black	Female	0	0	40
7	37	Private	284582	Masters	14	Married-civ-	Exec-manag	Wife	White	Female	0	0	40
8	49	Private	160187	9th	5	Married-spc	Other-servic	Not-in-famil	Black	Female	0	0	16
9	52	Self-emp-nc	209642	HS-grad	9	Married-civ-	Exec-manag	Husband	White	Male	0	0	45
10	31	Private	45781	Masters	14	Never-marri	Prof-special	Not-in-famil	White	Female	14084	0	50
11	42	Private	159449	Bachelors	13	Married-civ-	Exec-manag	Husband	White	Male	5178	0	40
12	37	Private	280464	Some-colleg	10	Married-civ-	Exec-manag	Husband	Black	Male	0	0	80

Welche Zusammenhänge könnten sich nun darin zeigen?

Unsere Daten-Blöcke helfen erstmal nicht so sehr weiter, weil sie meist numerische Daten verarbeiten. Wollen wir sie einsetzen, dann müssen wir die Spalten so skalieren, dass sich numerische Inhalte ergeben. Im einfachsten Fall ersetzen wir Texte einfach durch Zahlenwerte – und sollten uns dabei gut überlegen, welche Folgen das bezüglich ihrer Interpretation haben könnte.

Fangen wir mit der letzten Spalte an: Die Einkommenswerte werden nur für zwei Bereiche angegeben: kleiner oder größer als 50.000$. Wir ordnen diesen Bereichen die Werte 1 und 2 zu. (Oder 0 und 1, oder -1 und +1, oder 0 und 100, oder …. Hätten diese Änderungen Konsequenzen?) Um die Originaldaten nicht zu verändern, erzeugen wir eine Variable ***income*** und speichern dort die veränderten Werte, indem wir die Spalte 15 (income) ohne den ersten Wert (die Überschrift) in diese Variable kopieren und dann mithilfe des ***map…over…***-Blocks die Inhalte verändern. Jedenfalls versuchen wir das. Leider erhalten wir nur die unveränderte Spalte 13, wenn wir uns das Ergebnis wieder als Tabelle ansehen.

[21] Dabei handelt es sich um einen der Trainingsdatensätze für Maschinelles Lernen.

Was ist los? Wir sehen uns das erste Element von ***income*** an und überprüfen, ob es sich um eine Zeichenkette handelt. Das ist der Fall, aber sie ist länger als gedacht:

Wir müssen also vorher die führenden Leerzeichen rauswerfen. Das klappt jetzt: unsere Variable ***income*** enthält danach nur noch die Werte 1 und 2, wie wir durch Ansehen schnell überprüfen können.

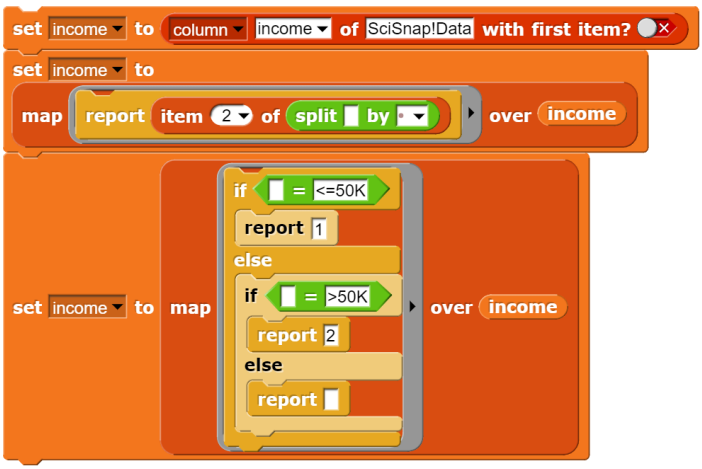

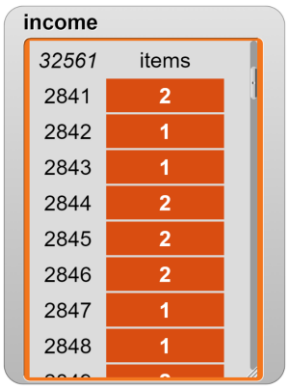

Wovon hängt dieses Einkommen nun ab?

Vielleicht vom Alter? Wir kombinieren die Spalte 1 (Alter) und unsere modifizierte Einkommensspalte zu einer neuen Tabelle namens ***testdata***.

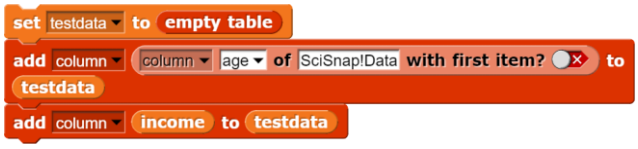

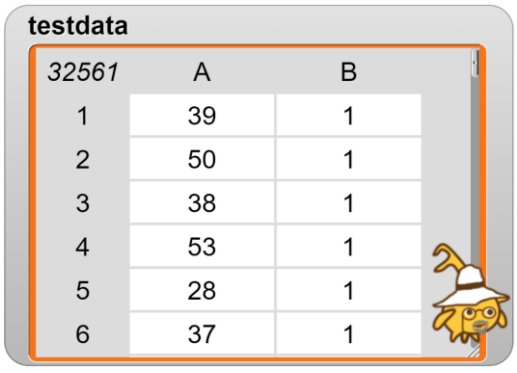

Den Zusammenhang zwischen Alter und Einkommen beschreiben wir durch den Korrelationskoeffizienten. Die Berechnung ist einfach:

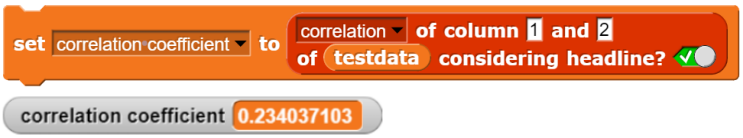

Und was bedeutet das?

<u>Aufgaben</u>:

1. Informieren Sie sich über die Bedeutung des Korrelationskoeffizienten und die Interpretation des erhaltenen Werts. Was bedeutet der Wert „0,2340…“?
2. Hängt der Korrelationskoeffizient in diesem Fall von der Art der numerischen Skalierung der Daten (1 und 2, -1 und 1, …) ab? Überprüfen Sie das.
3. Ermitteln Sie weitere Korrelationskoeffizienten, z. B. zwischen Ausbildung und Einkommen, Herkunftsland und Einkommen, Familienstand und Einkommen, Herkunftsland und Beruf, …
4. Informieren Sie sich darüber, ob und wann die Skalierung nichtnumerischer Daten einen Einfluss auf das Ergebnis haben kann.

5.14 New York Citibike Tripdata 2: Datenverarbeitung

Wir wollen mal nachsehen, wer in New York eigentlich Rad fährt. Dazu laden wir uns die Entleihdaten von NY Citibike eines Monats auf den Rechner, das sind die schon erwähnten knapp 600.000 Datensätze. Die sehen wir uns genauer an.

Table view

577704	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O
1	tripduration	starttime	stoptime	start station i	start station	start station	start station l	end station i	end station	end station l	end station k	bikeid	usertype	birth year	gender
2	695	2013-06-01 (	2013-06-01 (	444	Broadway &	40.7423543	-73.9891507	434	9 Ave & W 1	40.7431744	-74.0036644	19678	Subscriber	1983	1
3	693	2013-06-01 (	2013-06-01 (	444	Broadway &	40.7423543	-73.9891507	434	9 Ave & W 1	40.7431744	-74.0036644	16649	Subscriber	1984	1
4	2059	2013-06-01 (	2013-06-01 (	406	Hicks St & M	40.6951284	-73.9959506	406	Hicks St & M	40.6951284	-73.9959506	19599	Customer	NULL	0
5	123	2013-06-01 (	2013-06-01 (	475	E 15 St & Irv	40.7352427	-73.9875856	262	Washington	40.6917823	-73.9737299	16352	Subscriber	1960	1
6	1521	2013-06-01 (	2013-06-01 (	2008	Little West S	40.7056925	-74.0167768	310	State St & S	40.6892694	-73.9891286	15567	Subscriber	1983	1
7	2028	2013-06-01 (	2013-06-01 (	485	W 37 St & 5	40.7503800	-73.9833898	406	Hicks St & M	40.6951284	-73.9959506	18445	Customer	NULL	0
8	2057	2013-06-01 (	2013-06-01 (	285	Broadway &	40.7345456	-73.9907414	532	S 5 Pl & S 5	40.710451	-73.960876	15693	Subscriber	1991	1

Natürlich müssen wir uns bei der Quelle noch darüber informieren, was die Daten eigentlich bedeuten – also die Metadaten ansehen. Für das Geschlecht erfahren wir, dass 0: *unknown*, 1: *male* und 2: *female* bedeutet. Für die Spalten „*tripduration*“ und „*gender*“ ermitteln wir ein paar Daten:

Die mittlere Entleihdauer, bezogen auf das Geschlecht:

result

4	A	B
1	value	mean
2	0	1753.2988186817752
3	1	1063.5487225418608
2	2	1233.249445298994

Das dachten wir uns doch schon!

Wir sehen mal nach, ob die am Broadway fauler sind:

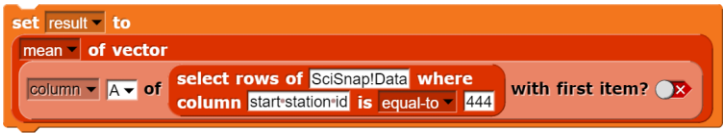

Aha. Wahrscheinlich ist es Central Park noch schlimmer!

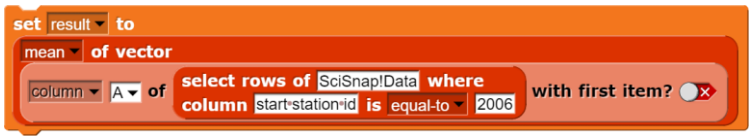

Na gut. Alle Vorurteile müssen ja nicht stimmen. 😉

Aufgaben:

1. Vielleicht fahren aber nur die Frauen am Central Park mehr Rad. Überprüfen Sie das.
2. Am Central Park gibt es ja nicht nur eine Entleihstation. Ermitteln Sie geeignete Mittelwerte für den ganzen Bereich.
3. Gibt es eigentlich auch Entleihdaten für andere Stadtteile? Suchen Sie mal und vergleichen Sie die Ergebnisse mit Manhattan.
4. Ermitteln Sie die mittleren Entleihdauern pro Wochentag, insgesamt und für einzelne Stationen. Gibt es da Unterschiede? Weshalb?
5. Oben wurde die mittlere Entleihdauer bezogen auf das Geschlecht berechnet. Man könnte das auch umgekehrt machen. Wäre das völliger Unsinn oder gibt es Fragestellungen, bei denen das sinnvoll wäre?

5.15 Under- und Overfitting

Maschinelles Lernen passt die Parameter einer Funktion mithilfe von Trainingsdaten so an, dass andere Werte gut prognostiziert werden – wenn alles klappt. Man baut also ein Prognoseinstrument, so eine Art „Fernrohr“ für Daten.

Man könnte nun meinen, dass so eine Funktion desto besser ist, je mehr anpassbare Parameter sie enthält. Dem ist aber nicht so. Einerseits erfordern (1.) mehr Parameter auch mehr Trainingsdaten und Trainingsläufe, also mehr Lernzeit; anderseits kann auch (2.) eine „unpassende“ Zahl der Parameter „gute“ Lösungen verhindern. Für beides geben wir jetzt ein Beispiel.

Zu 1: Beim Neuronalen Netz zur Verkehrszeichenerkennung (Beispiel 48) erzielen wir mit einer Schicht sehr gute Ergebnisse. Erhöhen wir die Zahl der Schichten und lassen die Zahl der Trainingsläufe gleich, dann verschlechtert sich drastisch die Erkennungsrate.

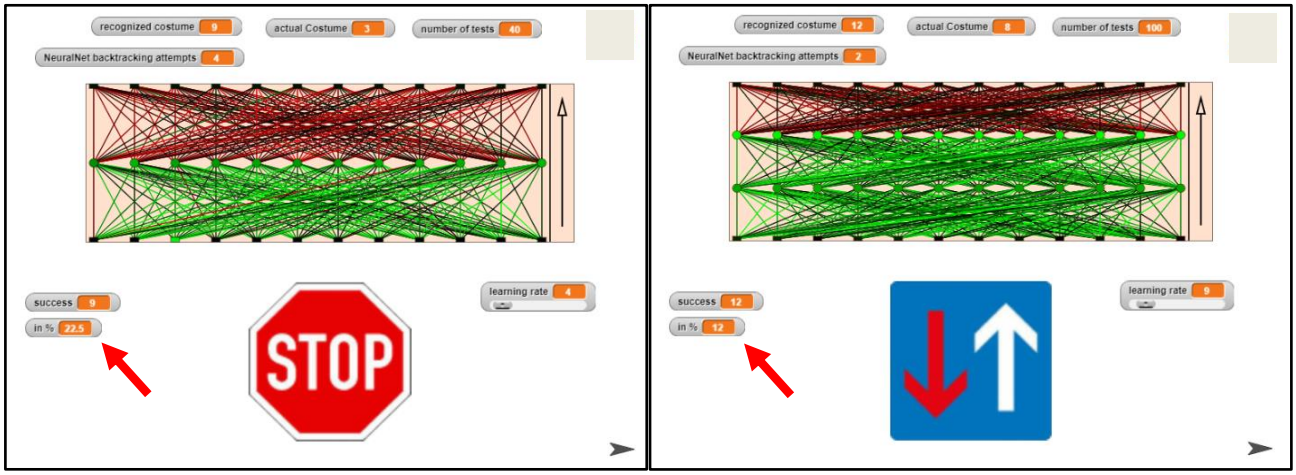

Zu 2: Wenn die Trainingsdaten von der Funktion gut reproduziert werden, dann heißt das noch lange nicht, dass das auch für andere Daten gilt. Es hängt sehr von der Art der Funktion ab, die erzeugt wird. Als Anwendung wählen wir das Beispiel *Polynominterpolation*.

Die Aufgabe lautet: *Mithilfe von Trainingsdaten werden die Koeffizienten eines Polynoms so angepasst, dass ANDERE Daten möglichst gut prognostiziert werden.*

Dafür müssen wir Daten erzeugen, mit deren Hilfe ein Interpolations-Polynom berechnet wird. Die Aufgabe übernimmt diesmal *Hilberto*. Er erzeugt Daten, die um die Parabel $0{,}5 * x^2 - 3$ streuen.

Wir konfigurieren ein zweites Sprite neben *Hilberto* namens *PlotPad* als PlotPad und stellen die Daten darauf dar.

Als „Arbeitspferd“ wählen wir das *PlotPad*. Benötigte Funktionalität aus anderen Bibliotheken importieren wir bei Bedarf von dort.

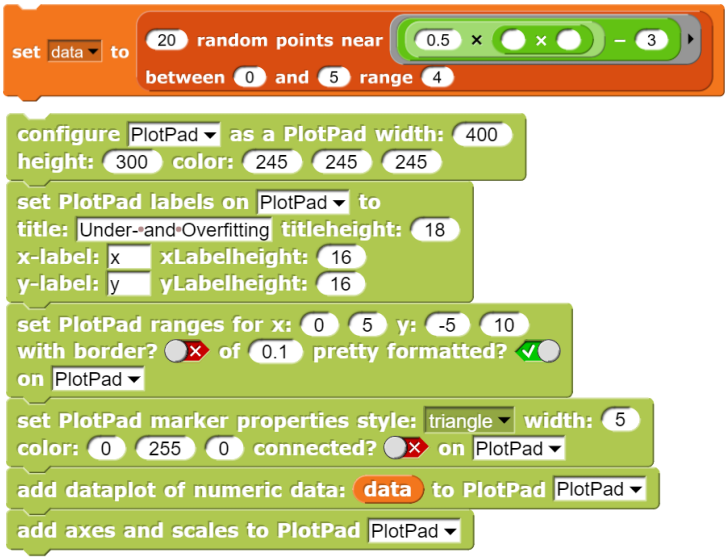

Das genügt schon, um die Daten darzustellen.

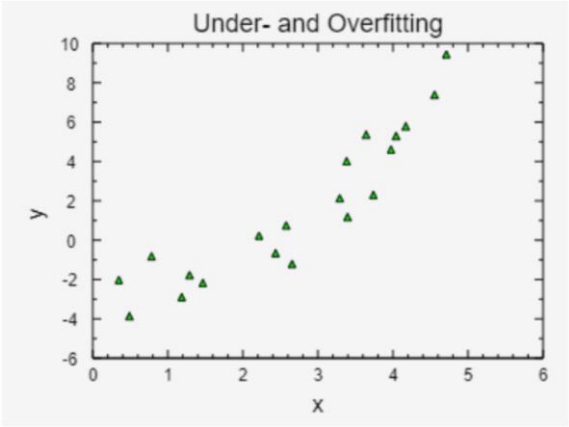

Die Interpolation probieren wir erst einmal mit einer Regressionsgeraden.

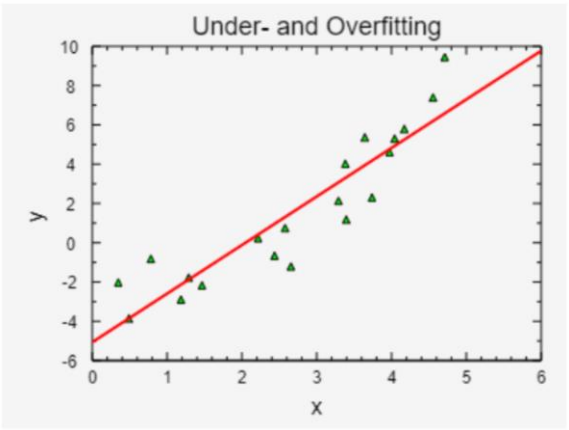

Das sieht eigentlich ganz nett aus, aber an den Seiten passt es nicht so recht.

Wir probieren es also mit einer Polynom-Interpolation.

Zuerst einmal wählen wir drei Zufallspaare aus den Trainingsdaten, bestimmen daraus das Interpolationspolynom und zeichnen es. Weil wir weiter experimentieren wollen, verallgemeinern wir die Lösung gleich zu einem Polynom durch *n* Punkte. Die Ergebnisse hängen davon ab, welche Punkte erwischt wurden. Anbei ein schlechtes und ein ganz gutes Ergebnis.

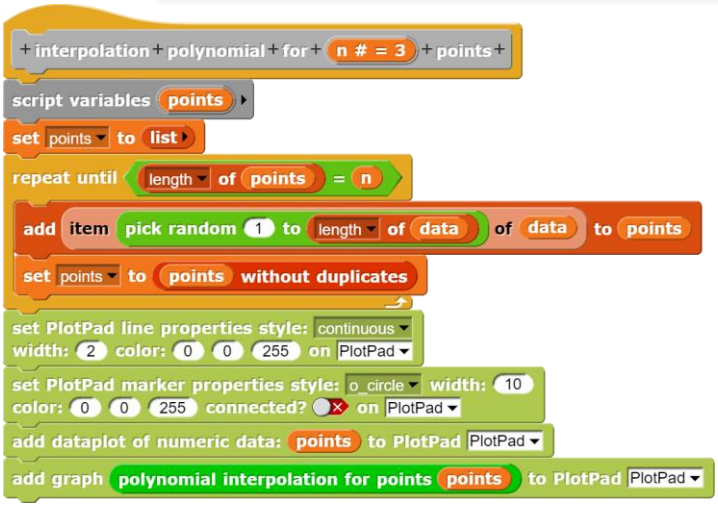

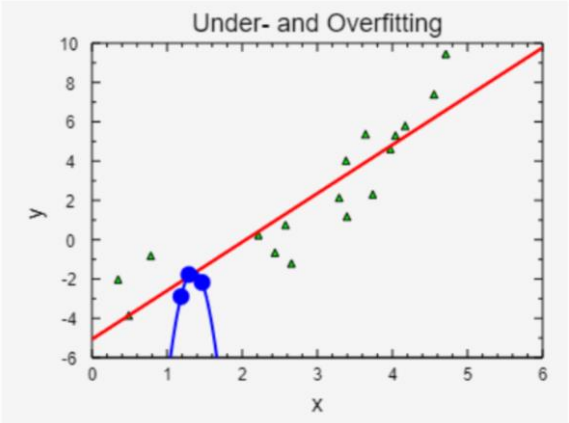

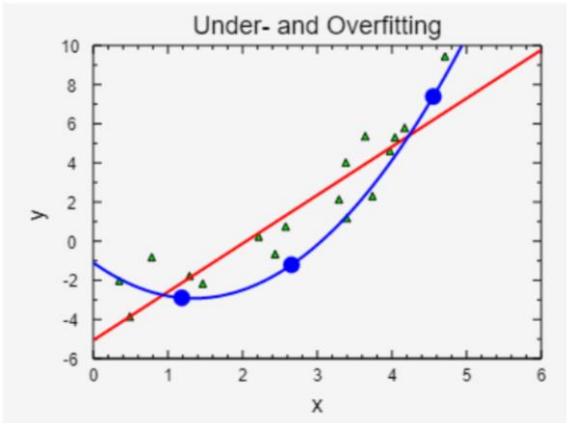

Jetzt werden wir mutig! Statt drei Punkten wählen wir 5. Wir wollen ja schließlich gute Arbeit abliefern! Das klappt halbwegs in der Mitte, und dann – upps!

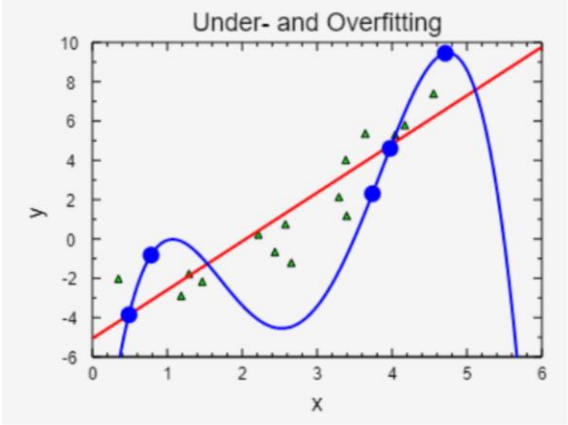

Vielleicht müssen wir ja einfach mehr Punkte nehmen. Versuchen wir es mit 10. Die Polynome verlaufen zwar durch mehr Punkte, aber an den Rändern „hauen sie ab“.

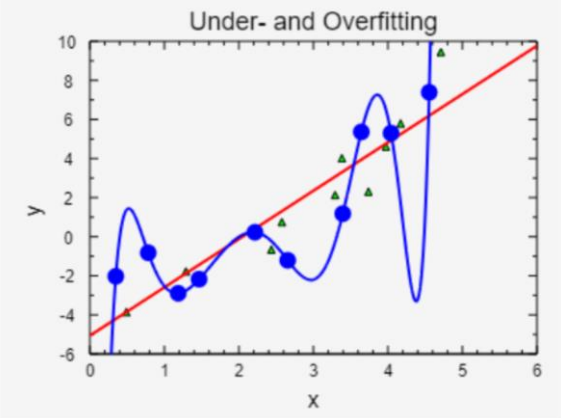

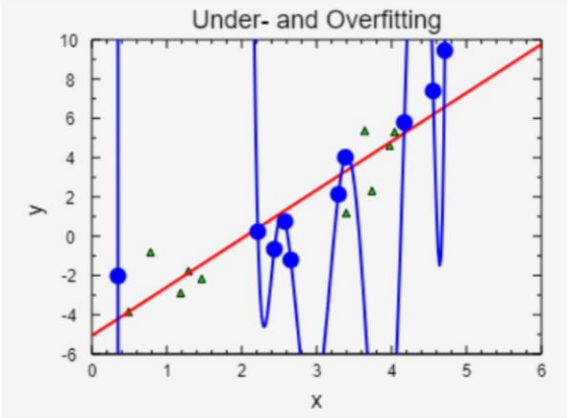

Na, dann mit allen Punkten!

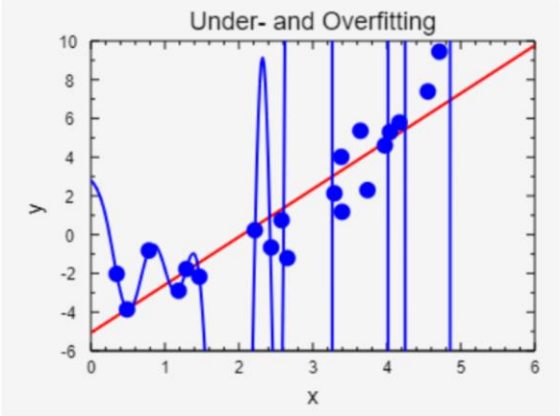

Man sieht, dass mit zunehmendem Grad des Polynoms zwar mehr Trainingsdaten direkt auf dem Graph liegen, dass aber dazwischen durch die wilden Oszillationen des Polynoms nur noch unsinnige Werte „prognostiziert“ werden.

Die Qualität des Gelernten hängt also sehr davon ab, wie wir mit Abweichungen umgehen. Wir müssen entscheiden, welche Ungenauigkeiten im Detail tolerierbar sind, damit die Prognose insgesamt zuverlässig wird. Ist der Grad des Polynoms zu klein, dann spricht man von *Underfitting*, ist er zu hoch, von *Overfitting*.

Aufgaben:

1. Diskutieren Sie unterschiedliche Möglichkeiten, einen „guten“ Grad des Interpolationspolynom (also seine höchste Potenz) festzulegen.
2. Formulieren Sie ihre Ergebnisse so präzise, dass sie sich als Skripte realisieren lassen.
3. Testen Sie die Skripte an unterschiedlichen Datensätzen.

5.16 New York Citibike Tripdata 3: World Map Library

Selbst in New York ist das Fahrradfahren inzwischen „hip“ geworden und die Entleihdaten können als CSV-Dateien geladen werden. Wir tun das wie in den vorherigen Beispielen mit diesem Datensatz. Da wir auch noch Grafiken erstellen wollen, konfigurieren wir ein Sprite als *PlotPad*.

Wir wollen doch mal sehen, wo man Fahrräder entleihen kann. Für die Übersicht extrahieren wir die Entleihstationen aus der Gesamtliste, z. B. indem wir sie nach dem Namen der Startstation (Spalte 5) gruppieren lassen und nur diese Spalte als Ergebnis wählen. Wir erhalten immerhin 337 Stationen. Da geografische Länge und Breite der Entleihstationen angegeben sind, bietet es sich an, die *World Map Library* von *Snap!* einzusetzen. Wir schreiben dafür einen kleinen Block, der die Umgebung einer Entleihstation als Karte darstellt.

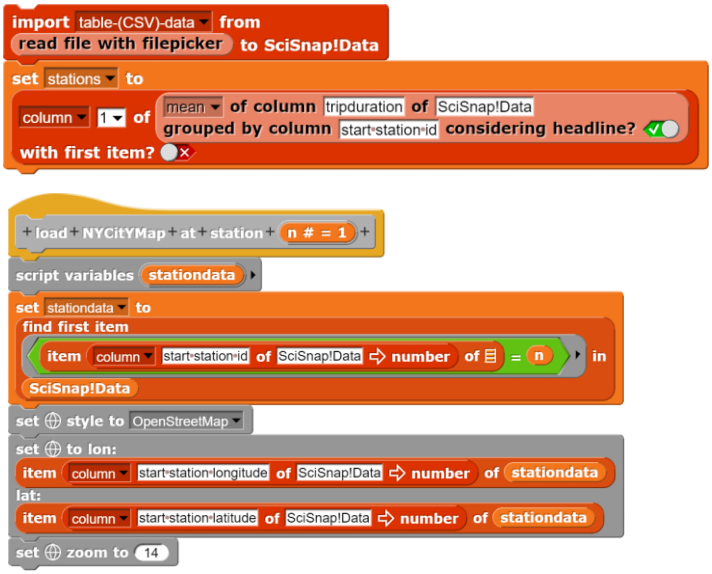

Danach suchen wir die Daten einer Station zusammen …

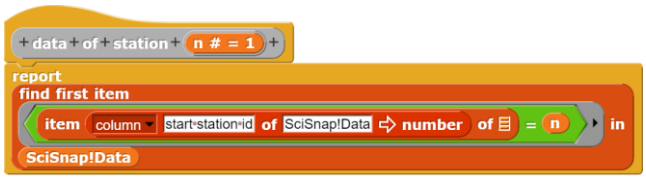

… und stellen so die Koordinatenliste der Stationen auf[22].

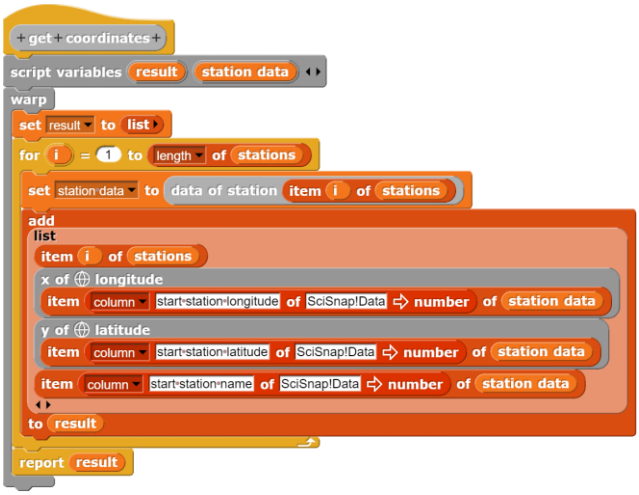

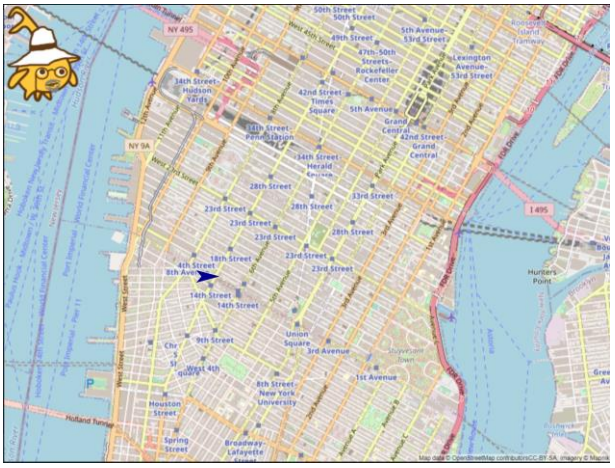

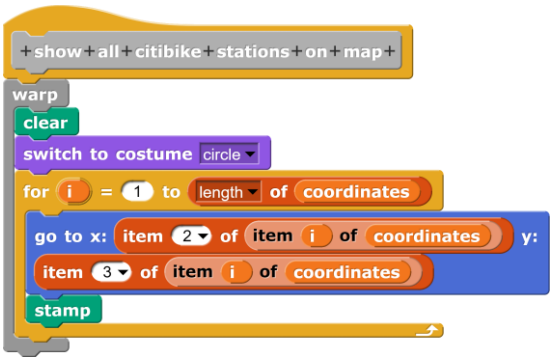

Mit diesen Daten können wir *Hilberto* zu den einzelnen Positionen schicken und dort mit dem *stamp*-Block z. B. zum Hinterlassen von Kreisen auffordern.

[22] Das dauert dann schon einige Zeit!

Zumindest in Midtown Manhattan müssen wir uns wohl keine Sorge darum machen, ob wir eine Entleihstation finden!

Wir wollen uns jetzt einmal die Verleihstation Broadway – Ecke 41 Street (Nr. 465) genauer ansehen. Dazu ziehen wir alle Datensätze aus der Gesamtliste, die an dieser Station starten oder enden. Das sind in diesem Monat 5054 Vorgänge. Zeiten sind in dieser Liste zusammen mit dem Datum eingetragen. Das können wir herauswerfen (Abtrennen mit *split* mit „ “) und auf die Stunde reduzieren (*split* mit „:“). Wir haben danach eine numerische Skala mit der Einheit „Stunde“. Jetzt können wir sehen, was in den einzelnen Stunden des Tages an der Station los ist.

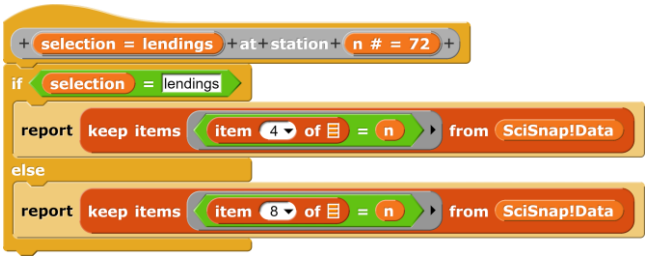

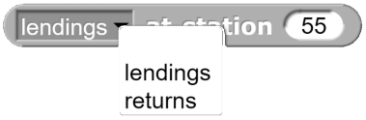

Und das können wir wie üblich grafisch darstellen.

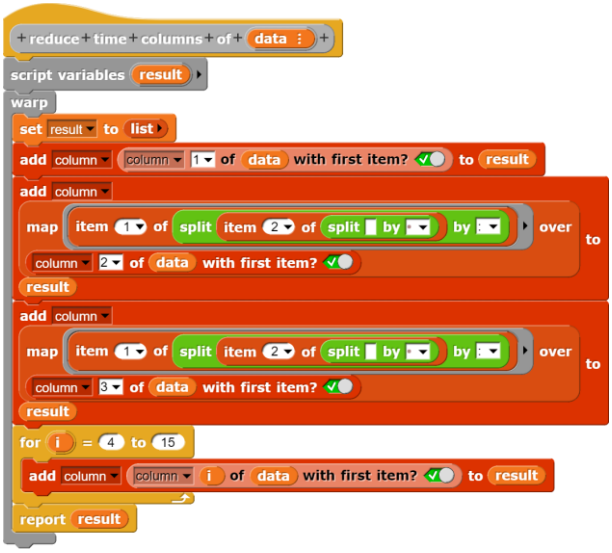

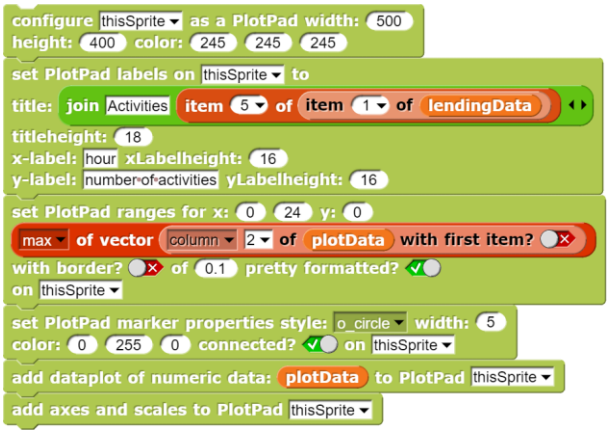

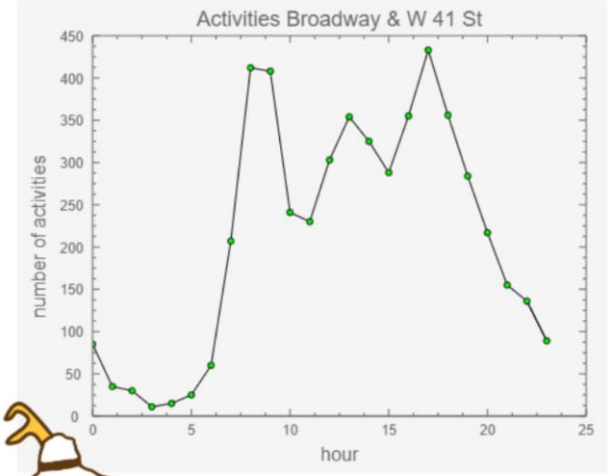

Das können wir natürlich zu einem Block zusammenfassen, wobei wir uns noch die Entscheidung offenlassen, ob wir Entleihungen, Rückgaben oder beides erfassen wollen.

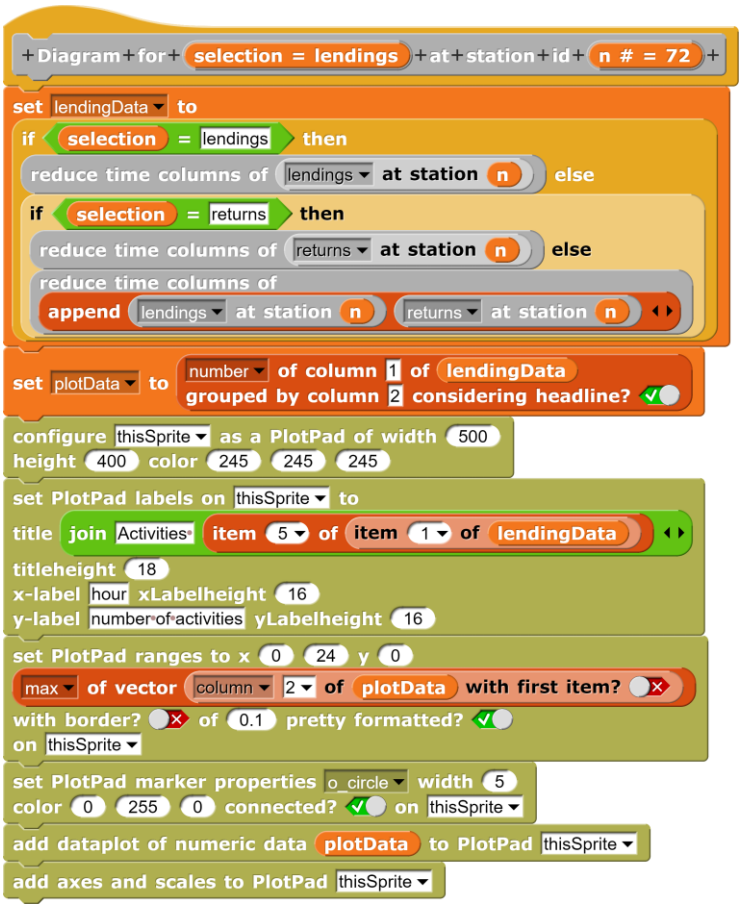

Ausleihen:

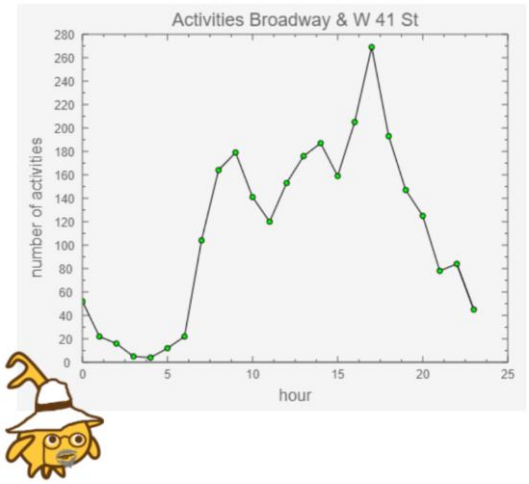

Rückgaben:

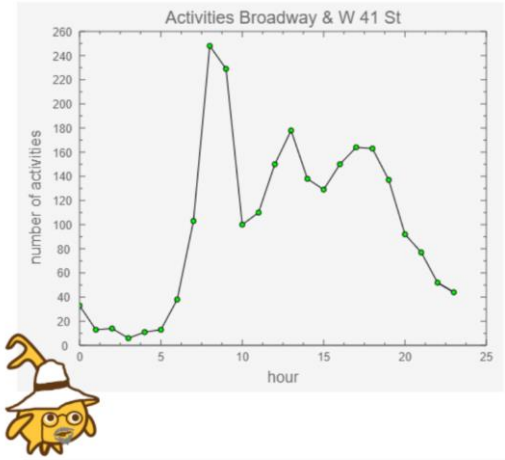

Ein paar Straßen weiter sieht es ganz ähnlich aus. Ist das ein allgemeines Muster?

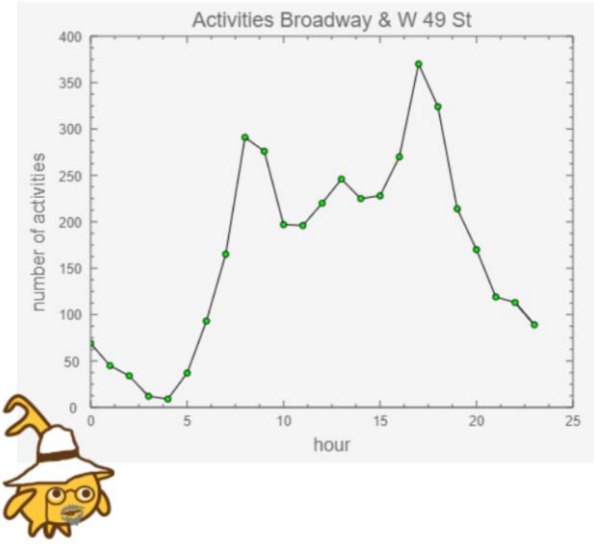

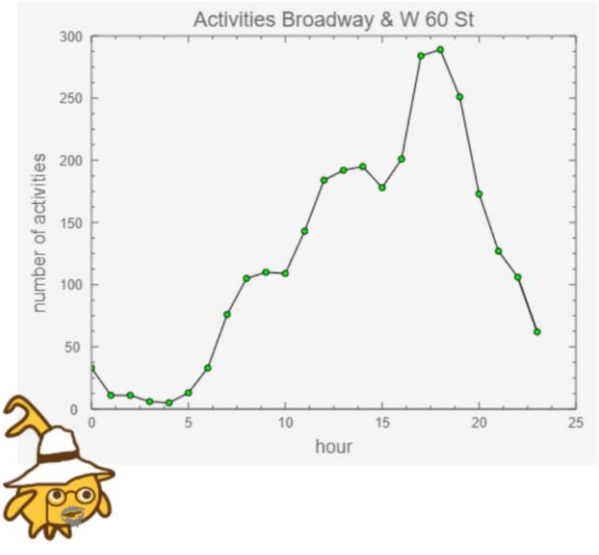

Nun gut, am Central Park stehen die Leute später auf und die Touristen sind noch nicht da. Dafür schließen die Museen immer zur gleichen Zeit.

Was können unsere Programme nun aus diesen Daten lernen?

- *Wir könnten z. B. aus den üblichen Ab- und Zugängen sowie dem Istbestand voraussagen, ob an einer Station noch rechtzeitig genügend Fahrräder zurückgegeben werden oder ob es besser wäre, einige dorthin zu transportieren.*
- *Wir könnten aus den mittleren Weglängen ermitteln, welche Akkus für eBikes gebraucht werden.*
- *Wir könnten feststellen, ob eher Frauen oder Männer zu einer bestimmten Tageszeit die Räder entleihen und dann dafür sorgen, dass das Angebot stimmt. Das Entsprechende könnten wir für das Alter der Entleihenden machen.*
- *Wir könnten die Entleihdaten pro Rad ermitteln und voraussagen, wann Reparaturen fällig sein werden. Wir könnten das z. B. auch in Abhängigkeit von der Lage der Stationen machen.*
- *Wir könnten versuchen, Verteilungen von einigen Stationen so zu verallgemeinern, dass sich Prognosen für andere daraus ableiten lassen. Wenn also am Central Park die Museen schließen, kann das Programm aus den alten Daten „lernen“, in welchen Bezirken die Räder wann vermutlich abgegeben werden, und warnen, falls dort nicht genug freie Slots zur Verfügung stehen.*

usw.

Aufgaben:

1. Gliedern Sie die Aktivitäten der Stationen nach Zu- und Abgängen auf.
2. Schreiben Sie eine Prognosefunktion, die warnt, wenn in den nächsten Stunden ein Radmangel an einer Station droht.
3. Stellen Sie für bestimmte Stationen durch direkte Linien die Verbindungen zu den meist gewählten Abgabestationen graphisch auf der Karte dar. Wählen Sie die Liniendicke entsprechend der Anzahl der Entleihvorgängen und die Farben je nach Station. Bilden sich Cluster?
4. Stellen Sie mithilfe von Korrelationen fest, ob es Zusammenhänge im Entleihverhalten (z. B. bzgl. der Tageszeiten, dem Ort, …) mit dem Geschlecht, dem Alter, dem Status der Entleihenden gibt. Ggf. müssen Sie die Daten vorher durch numerische Daten ersetzen – ähnlich wie bei den Zeiten. Diskutieren Sie mögliche Konsequenzen.
5. Ermitteln Sie für einen kleinen Abschnitt von Midtown (dort, wo alles schön rechteckig ist) die Koordinaten der Straßenecken. Entwickeln Sie dann einen Router, der den kürzesten Weg zur nächsten Citibike-Station anzeigt.
6. Die Entleihzahlen abhängig von der Tageszeit zeigen in unterschiedlichen Bereichen Manhattans ziemliche Unterschiede. Untersuchen Sie Gemeinsamkeiten und Unterschiede systematisch und versuchen Sie, die Ergebnisse zu erklären.

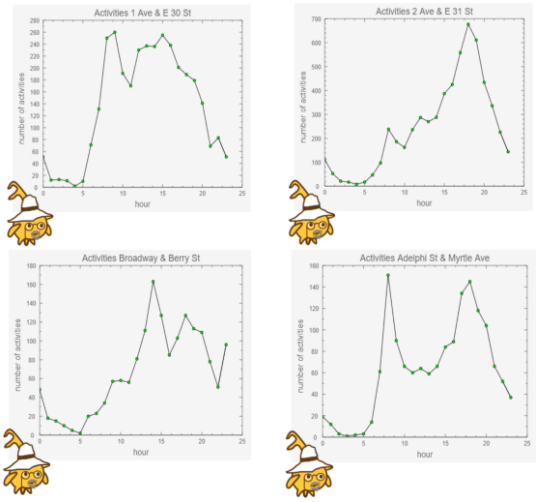

5.17 Sternspektren [UniGOE]

Sterne leuchten in unterschiedlichen Farben, weil sie unterschiedliche Temperaturen haben. Zusätzlich unterscheiden sich die Spektren in ihren Absorptionslinien. Das wollen wir etwas genauer untersuchen.

Wir besorgen uns einige Sternspektren (Quelle: [UniGOE]) und speichern sie als Textdatei. Solch eine lesen wir ein und zerlegen sie gleich in eine Liste *data*. In der ersten Zeile steht nach den Spaltenbeschriftungen der Sternname. Den isolieren wir und speichern ihn als *starname*.

Wir wissen jetzt, wie der Stern heißt. Wenn Sie im Internet danach suchen, finden Sie eine Fülle von Informationen darüber. Damit wir den Ladevorgang mit anderen Daten wiederholen können, kapseln wir ihn in einem eigenen Block. Nach dessen Ausführung liegen die eigentlichen Sterndaten als leicht aufbereitete Tabelle vor. Unschön daran ist die stark unterschiedliche Größenordnung der Daten in den beiden Spalten. Wir normalisieren deshalb die zweite Spalte mithilfe des Mittelwerts und speichern das Ergebnis als ***normalizedData***.

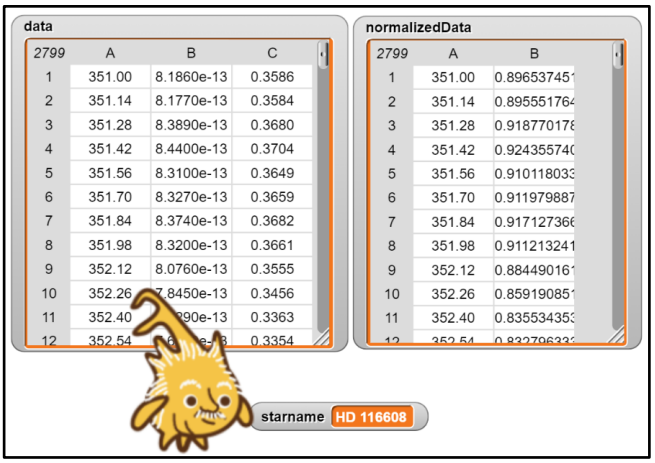

Mit den normalisierten Daten lässt sich schnell ein Diagramm auf einem *PlotPad* erstellen.

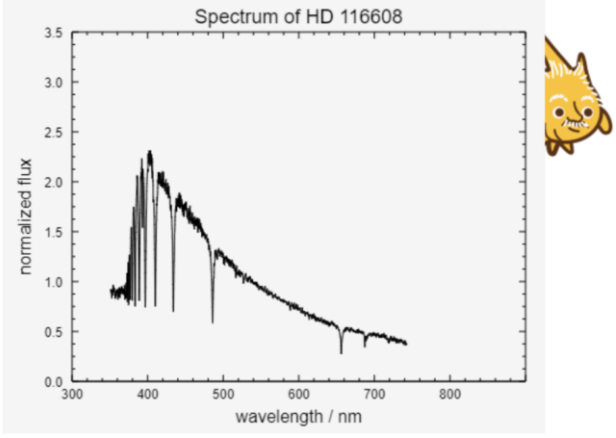

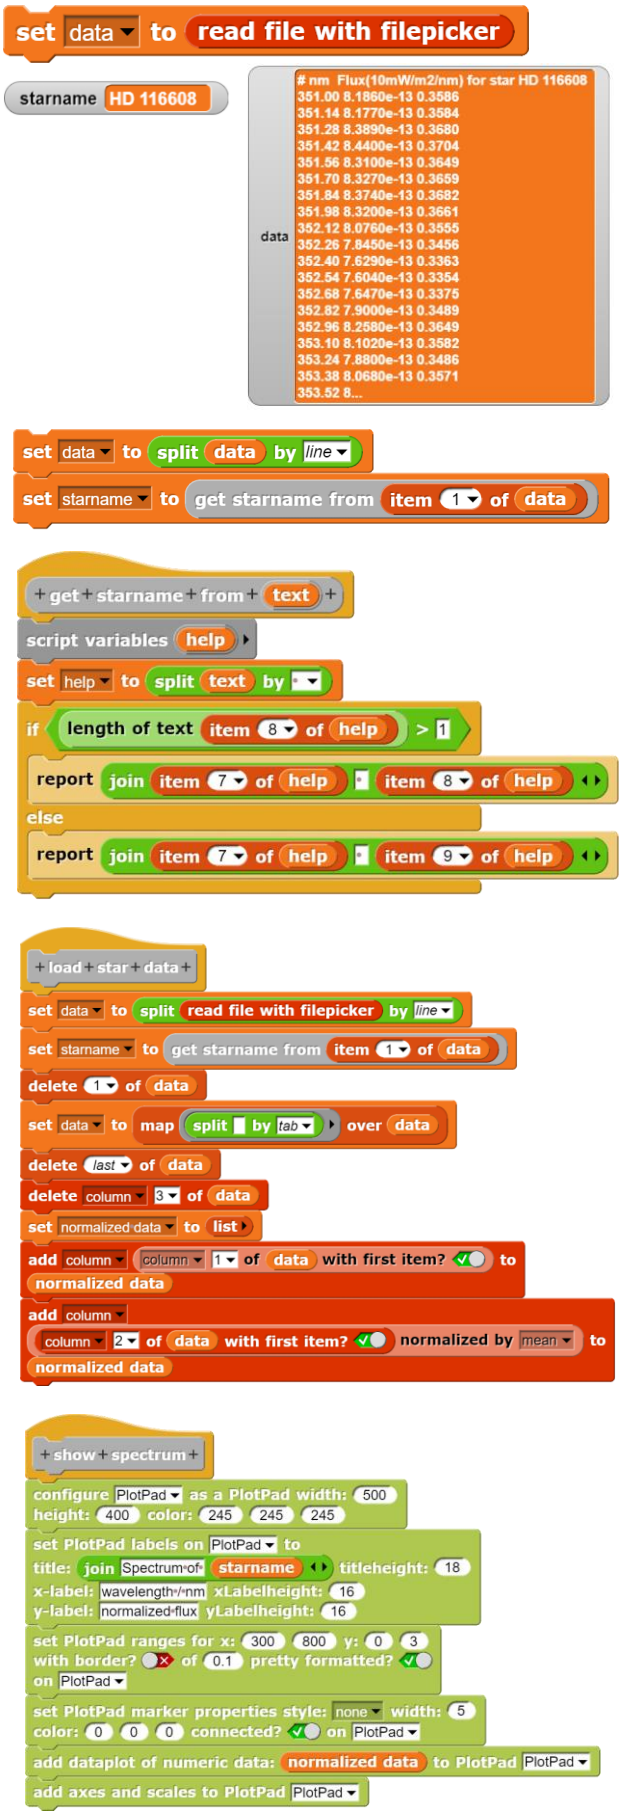

Man erkennt gut den abfallenden Verlauf mit einigen markanten Absorptionslinien. Aber braucht man für diese Erkenntnis überhaupt alle Spektraldaten? Vielleicht genügt es ja, durch Mittelwertbildung die Datenmenge zu reduzieren. Wir führen einen Kompressionsfaktor *compressionRate* ein und ergänzen das Skript vor der Diagrammerstellung.

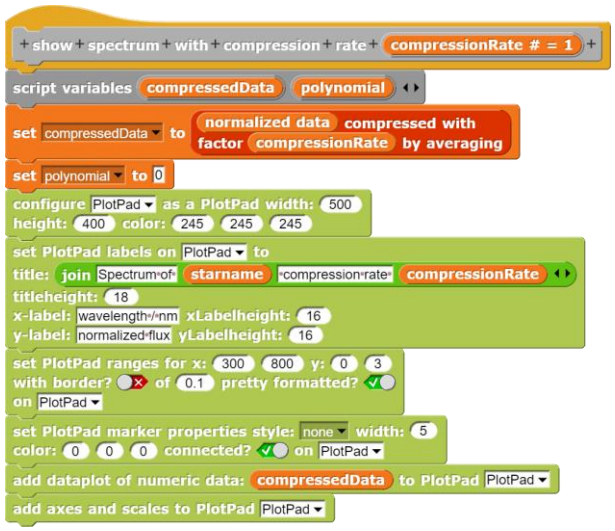

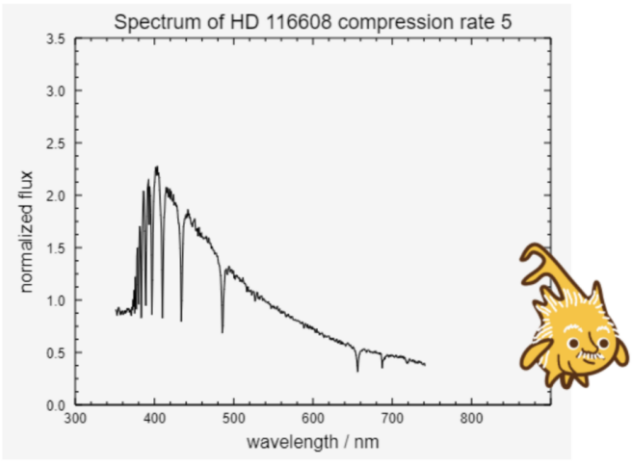

Der Faktor 5 ändert nicht viel.
Probieren wir also weiter.

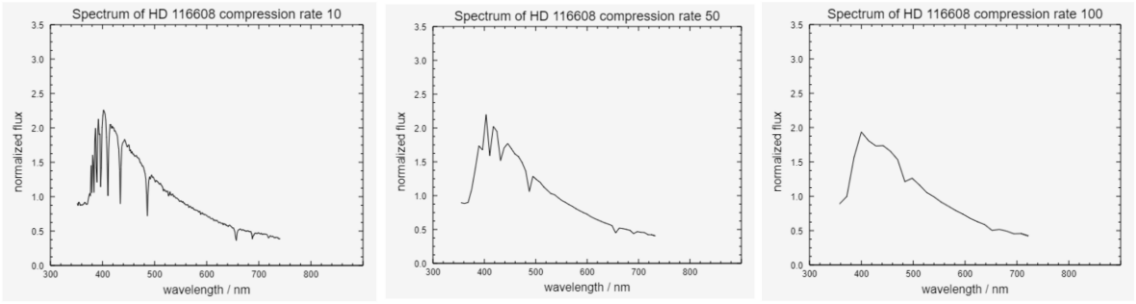

Man sieht, dass der temperaturabhängige Verlauf des Spektrums kaum verändert wird.
Nur die Absorptionslinien gehen verloren.

Somit sollte sich der Typ des Spektrums durch ein Interpolationspolynom z. B. 4. Grades beschreiben lassen.

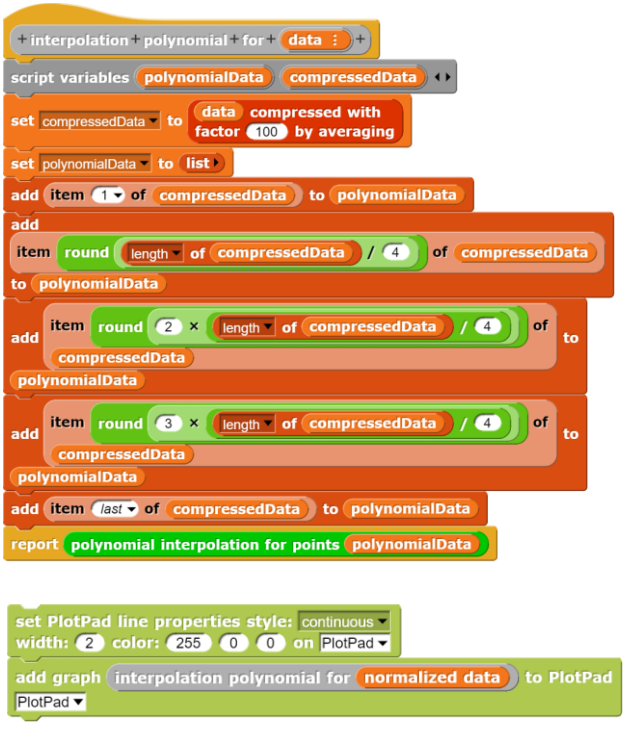

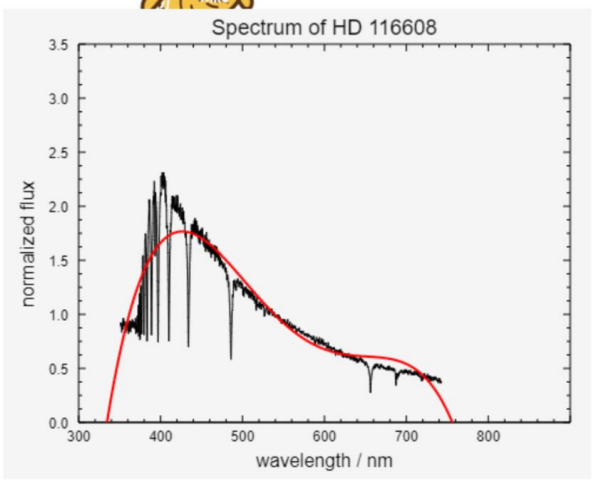

Das funktioniert also hervorragend! Protokollieren wir die Polynomparameter bei der Untersuchung gleich mit, dann können wir anhand der Parameterbereiche die Sterntypen leicht unterscheiden.

7	A	B	C	D	E	F
1	star name	a4	a3	a2	a1	a0
2	HD 116608	-1.2493580327340172e-9	0.000002886821087800814	-0.002459579857425176	0.9103088865090065	0.9103088865090065
3	HD 158659	1.5652590170171166e-10	-3.963032080178107e-7	0.0003879661846290463	-0.17622312866994078	-0.17622312866994078
4	HD 10032	-7.27005023271818e-10	0.00000169492984799 1264	-0.001462425925103779	0.5500801501694278	0.5500801501694278
5	HD 28099	-4.0018935572381893e-10	9.399457129604694e-7	-0.0008209889485783107	0.3141072191721327	0.3141072191721327
6	HD 23524	-8.18301248511472e-11	2.3253458278204257e-7	-0.0002461580054487 6965	0.11348374829256708	0.11348374829256708
7	HD 260655	6.248027476637483e-10	-0.000001337322548726115	0.0010450333683869723	-0.3486709605339992	-0.3486709605339992

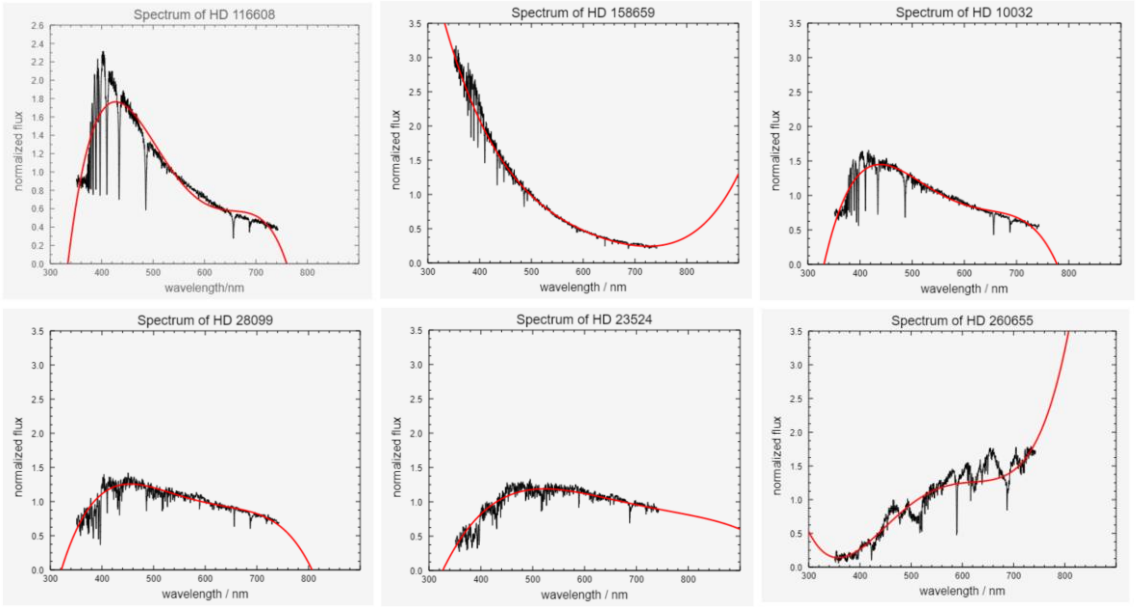

Füttert man mit den Polynomkoeffizienten ein Neuronales Netz, dann lernt dieses schnell, ein Diagramm grob einem Sterntyp zuzuordnen. Das Programm kann anhand der alten Daten also „lernen“ welche Parameterintervalle zu welchen Sternklassen gehören. Gibt man die Daten eines neuen Sterns ein, dann ermittelt es die Koeffizienten des Polynoms und gibt danach eine gut begründete Prognose ab, um welche Art von Stern es sich handeln könnte.

Aufgaben:

1. Stellen Sie für die nicht komprimierten Spektrumsdaten jeweils ein Interpolationspolynom möglichst niedrigen Grades auf. Welche Punkte sollten dafür gewählt werden? Ergeben sich Unterschiede zwischen diesen Polynomen und den Ergebnissen des oben gezeigten Verfahrens?
2. Entwickeln Sie ein Skript, das ein unbekanntes Spektrum einem der bisher auftretenden Typen zuordnet.
3. Entwickeln Sie ein Verfahren, um die markantesten Absorptionslinien genauer zu untersuchen. Stellen Sie diese für Sterne der gleichen Klasse vergrößert dar und versuchen Sie, Unterschiede „automatisch“ zu bestimmen. Diskutieren Sie Ihre Ideen vor der Realisierung.

5.18 Klassifizierung mit dem kNN-Verfahren

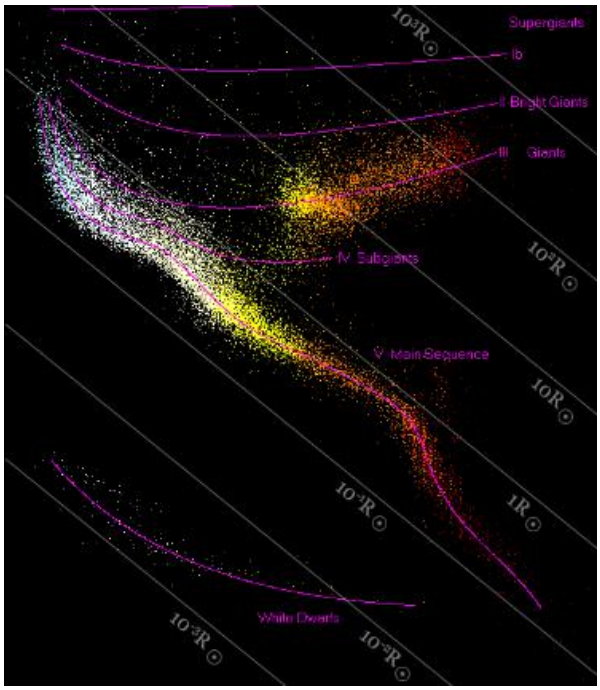

Im Hertzsprung-Russel-Diagramm (s. Wikipedia) wird die Leuchtkraft von Sternen über ihrer Sternklasse aufgetragen. Es ergibt sich einen Art Linie von links-oben-nach rechts-unten, die „Hauptreihe“. Auf dieser halten sich Sterne wie die Sonne überwiegend auf. Rechts-oben über der Hauptreihe finden wir die Roten Riesen, links-unten unter der Hauptreihe die Weißen Zwerge. Das reicht erstmal. (Bildquelle: [HR])

Wir wollen neue Sterne in diesem Diagramm klassifizieren, indem wir das Verfahren der k-nächsten-Nachbarn (*kNN*) verwenden: Wir erzeugen als Trainingsdaten eine Liste von Sternen mit deren Koordinaten (einfach als Bildkoordinaten im Diagramm) und deren Typ. Wollen wir einen neuen Stern klassifizieren, dann bestimmen wir seine Position im Diagramm und suchen die nächsten *k* (z. B. *k=5*) Nachbarn. Danach bestimmen wir den am häufigsten auftauchenden Sterntyp in dieser Liste. Den weisen wir dem neuen Stern zu.

Zuerst einmal benötigen wir ein Bild des Hertzsprung-Russel-Diagramms ([HR]). Dieses importieren wir in *Snap!* als Kostüm eines *ImagePads* und erzeugen daraus die benötigten Daten. Da wir auf dem Bild zeichnen wollen, arbeiten wir mit einer Kopie des HR-Diagramms, um das Original nicht zu verändern.

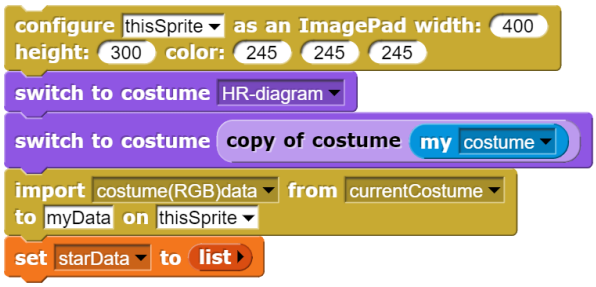

Die Trainingsdaten erhalten wir, indem wir einen Sterntyp vorgeben und danach einige Punkte im Diagramm anklicken, die diesem Typ entsprechen.

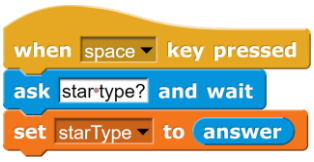

Danach können wir neue Sterne klassifizieren, indem wir sie anklicken und beschriften.

Wir stellen dazu einige Properties für die Darstellung ein und zeichnen einen Kreis am Ort des Sterns. Danach bestimmen wir die fünf nächsten Nachbarn und die Anzahlen des Auftretens ihres Typs. Im Ergebnis löschen wir die Überschriften und sortieren die Liste absteigend. Der Typ des neuen Sterns steht dann als erstes Element in der ersten Zeile. Diesen schreiben wir neben den Stern.

Das Ergebnis:

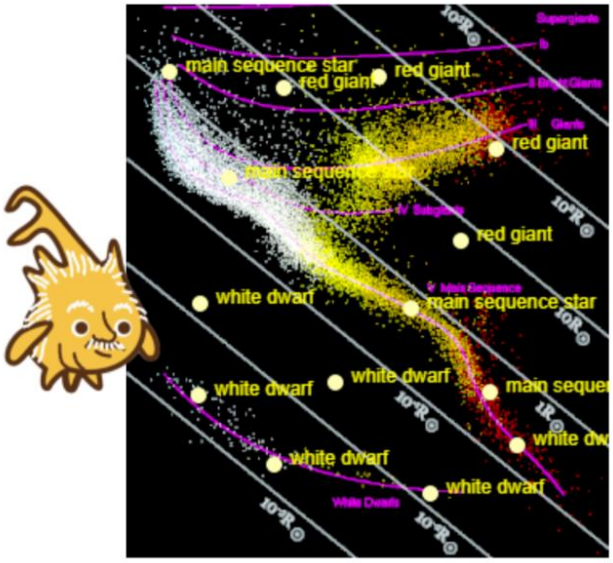


```
+ draw + type + of + star + point ⋮ +
script variables neighbours startypes type
set ImagePad line properties style: continuous
width: 1 color: 255 255 0
fill color: 255 255 180 on thisSprite
fill circle center: item 1 of point item 2 of point radius: 5 on
thisSprite
set neighbours to 5 next neighbors of point
in starData
set startypes to number of column 2 of neighbours
grouped by column 2 considering headline?
delete 1 of startypes
set startypes to startypes sorted by column 2
ascending considering headline?
set type to item 1 of item 1 of startypes
draw text type at 10 + item 1 of point item 2 of point
height: 12
horizontal? on thisSprite
```

Aufgaben:

1. Fügen Sie die neu klassifizierten Sterne der Beispielliste hinzu, sodass sie bei weiteren Klassifizierungen mit hinzugezogen werden.
2. Zeichnen Sie für die unterschiedlichen Sternarten unterschiedlich farbige Punkte an den richtigen Stellen auf das Sprite, statt sie zu beschriften.
3. Lassen Sie den Prozess für zufällig ausgewählte Punkte ablaufen. Entsteht immer das gleiche Muster? Entstehen völlig verschiedene oder ähnliche Muster? Wovon hängt das ab?

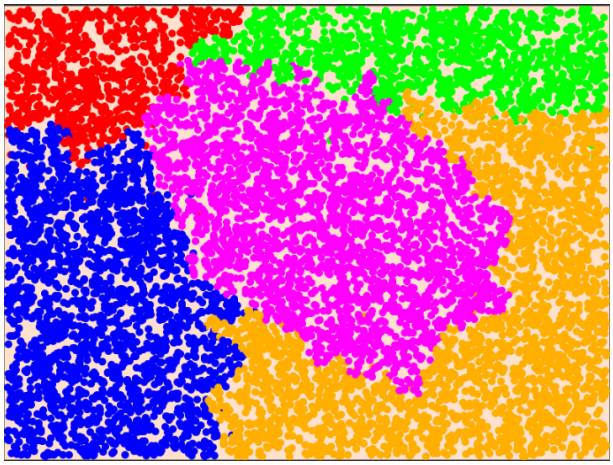

5.22 Zeichnen einer Funktion und ihrer Ableitungen

Wir wollen ein *SciSnap!PlotPad* dazu benutzen, eine Funktion und ihre ersten beiden Ableitungen in unterschiedlichen Farben und Linienarten darzustellen. Dazu erzeugen wir ein neues Sprite, wechseln in seinen Skriptbereich und konfigurieren es geeignet. Die Funktionsterme werden einmal als „ringified“ Operator, dann zweimal als Liste von Polynom-Koeffizienten angegeben.

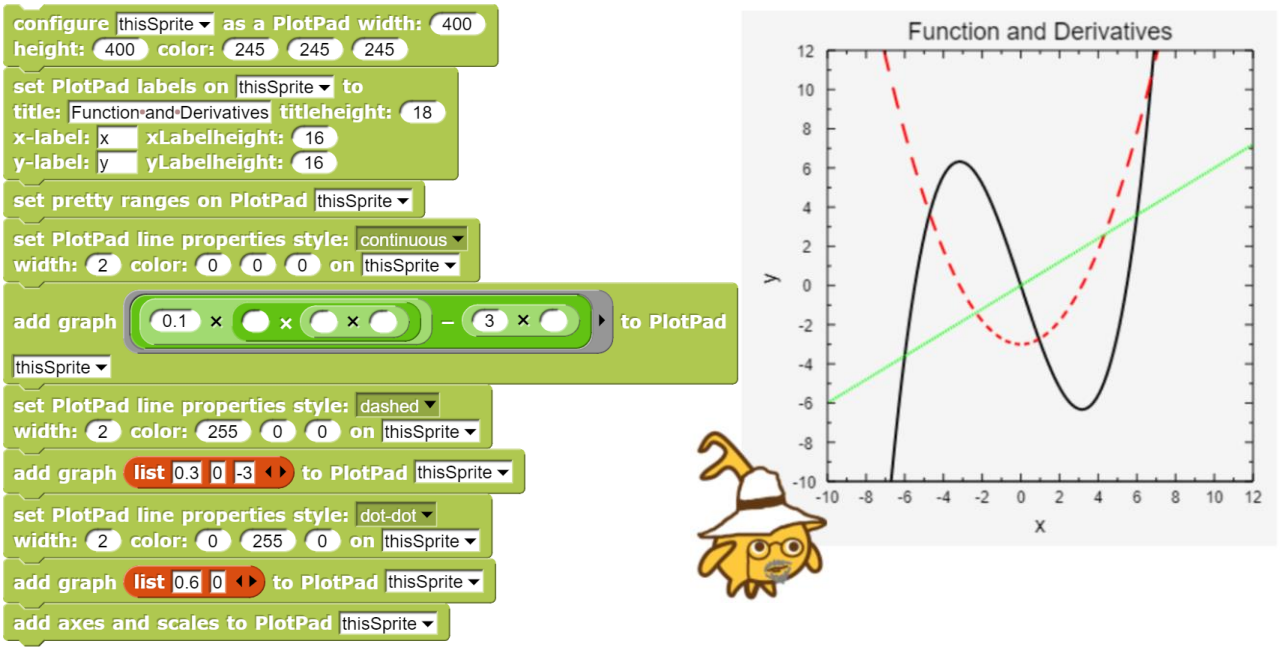

Aufgaben:

1. Stellen Sie unterschiedliche Funktionstypen (trigonometrische Funktionen, Logarithmen, Polynome, …) als Graph auf einem *PlotPad* dar.
2. Ergänzen Sie die Funktionsgraphen durch deren Ableitungen.
3. Wählen Sie für die Darstellungen unterschiedliche Wertebereiche, Genauigkeiten der Zahlendarstellung und Textgrößen und Beschriftungen.

5.23 Datenplot von Punkten, die um einen Funktionsgraphen streuen

Wir erzeugen einige Datenpunkte in der Nähe des Graphen zu $f(x) = x^3 - x$ und stellen sie auf einem *PlotPad* dar. Damit sie schön geordnet auftreten, sortieren wir die Punkte vor der Erstellung des Diagramms, und weil heute Sonntag ist, werden sie in Regenbogenfarben verbunden.

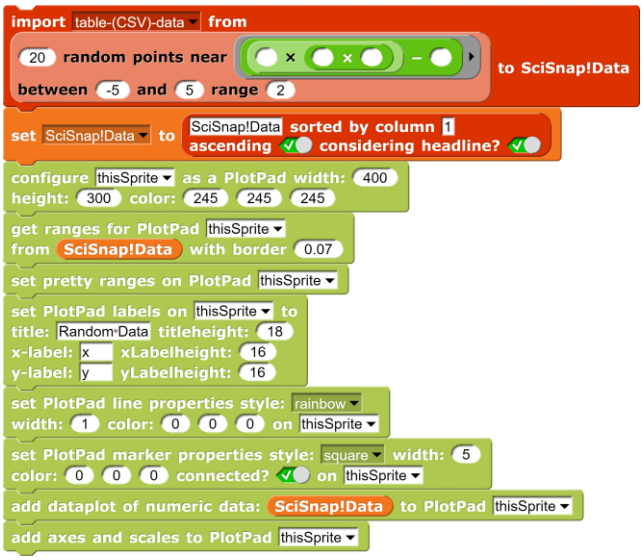

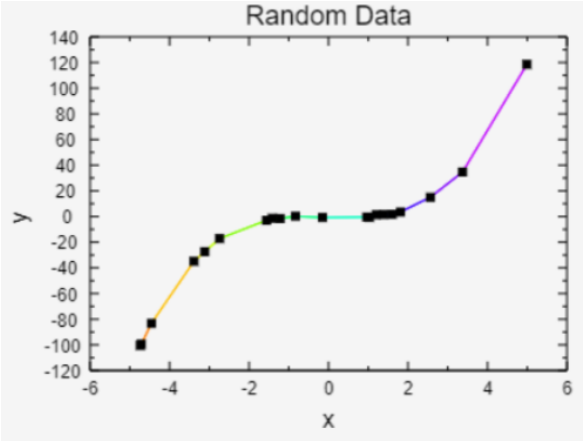

5.24 Histogramm von Zufallswerten

Wir erzeugen wiederum Zufallspunkte, die um den Graphen zu $f(x) = x^3 - x$ streuen, wählen aber diesmal nur die erste Spalte als Datenmenge. Von diesen Werten lassen wir ein Histogramm mit 10 Säulen erstellen.

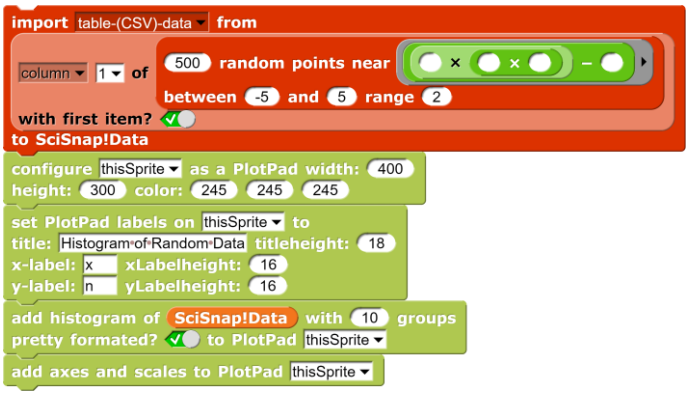

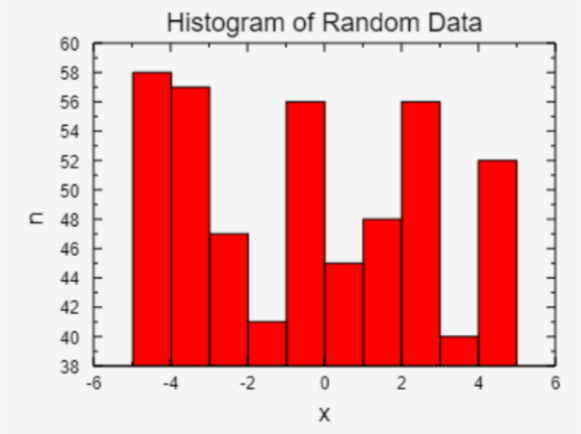

5.25 Auswertung von Covid-19-Daten

Wir laden die Covid-19-Zahlen der Johns-Hopkins-Universität vom 1.3.2020 bis 19.4.2020 für vier Länder in den Datenbereich von *SciSnap!* und erhalten:

55	A	B	C	D	E	F
1		Covid-10 Infections from 1.3.2020				
2		origin: Johns-Hopkins-University				
3						
4			Infected			
5	Date	Day	Germany	Italy	USA	China
6	1.3.	1	119	1694	43	79826
7	2.3.	2	152	2036	67	80026
8	3.3.	3	190	2502	88	80151
9	4.3.	4	264	3089	117	80271
10	5.3.	5	402	3858	186	80422
11	6.3.	6	641	4636	232	80573
12	7.3.	7	797	5883	351	80652
13	8.3.	8	900	7375	469	80699
14	9.3.	9	1146	9172	535	80735
15	10.3.	10	1567	10149	892	80757
16	11.3.	11	1968	12462	1214	80785
17	12.3.	12	2747	12462	1596	80793
18	13.3.	13	3677	17660	1647	80801
19	14.3.	14	4587	21157	2656	80827
20	15.3.	15	5815	24747	3338	80848

Da wir uns nur für die reinen Daten interessieren, greifen wir den relevanten Datenbereich für ein Land heraus.

data

51	A	B
1	Day	Germany
2	1	119
3	2	152
4	3	190
5	4	264
6	5	402

Darüber verschaffen wir uns erstmal einen Überblick:

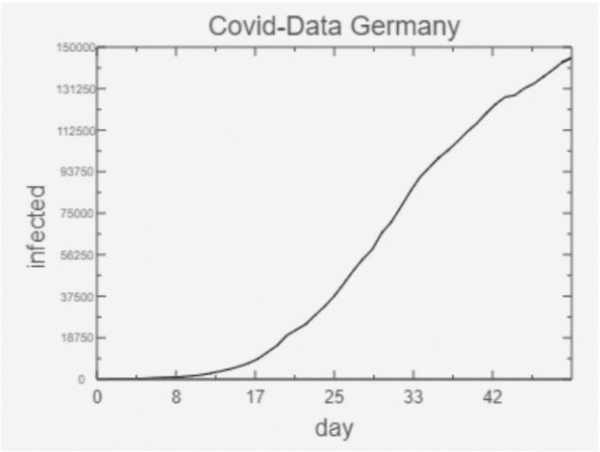

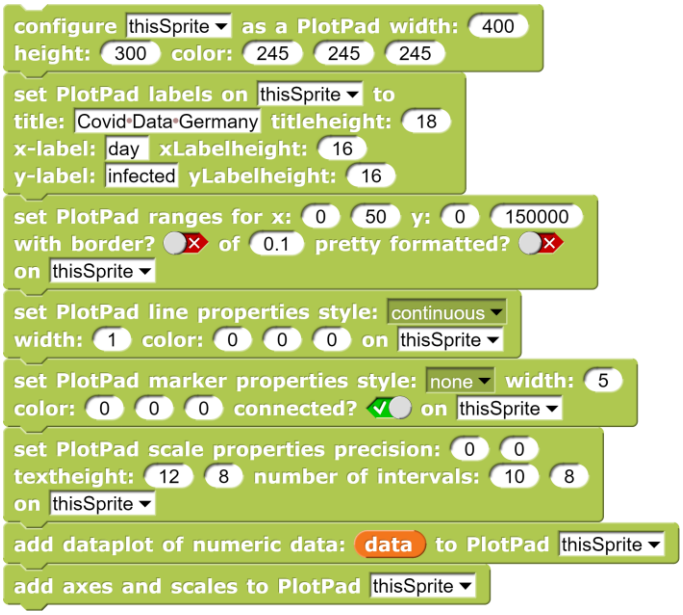

Dann probieren wir es doch einmal mit einer halblogarithmischen Darstellung …

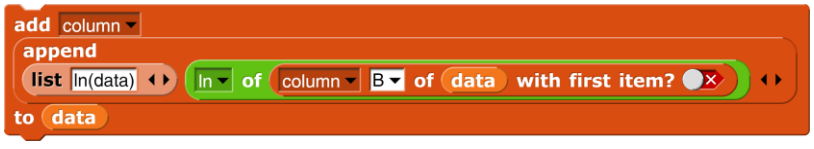

… greifen die beiden interessanten Spalten heraus …

… und passen das Diagramm an: Wir zeigen die halblogarithmisch aufgetragenen Daten und die Regressionsgeraden für die beiden Hälften der Daten.

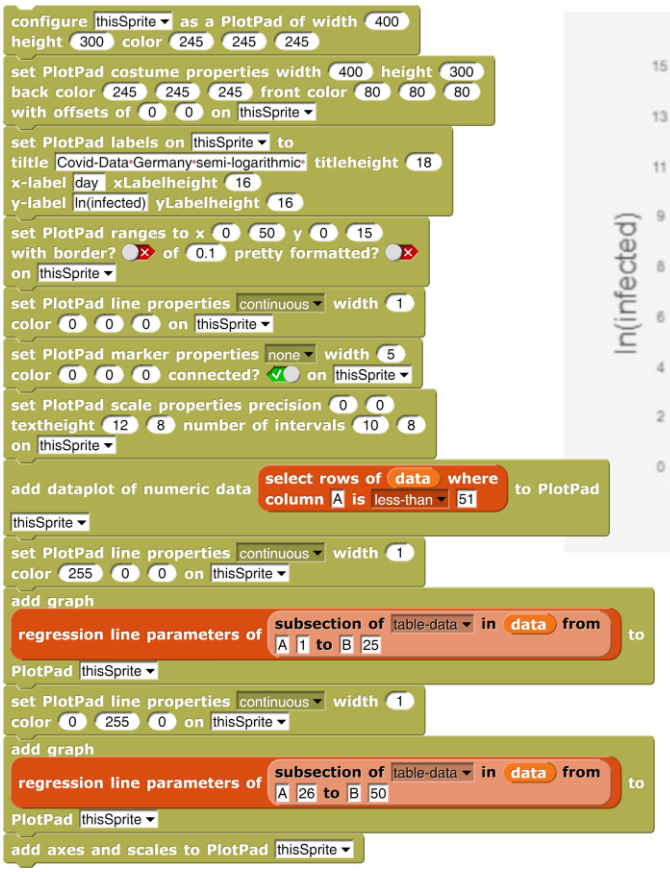

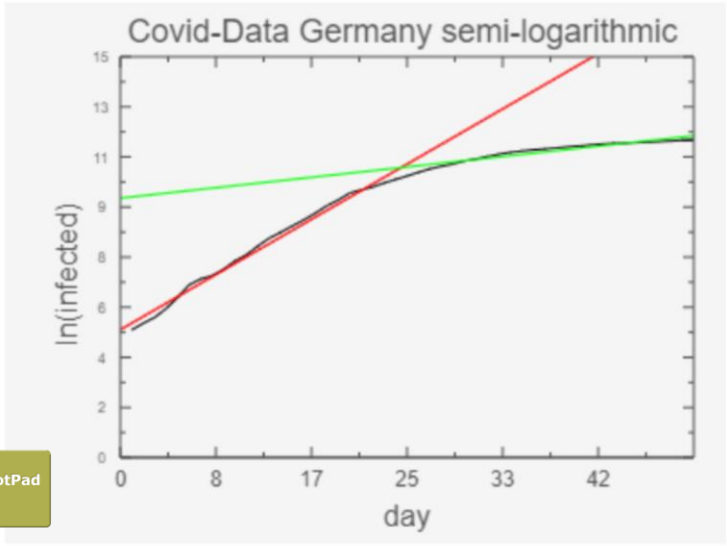

Da kam Hoffnung auf!

Aufgaben:

1. Stellen Sie die Daten für die anderen Länder ebenfalls grafisch dar.

2. Versuchen Sie festzustellen, ob es Zusammenhänge zwischen den Datenreihen gibt.

5.26 Schattenlängen im Mondkrater Tycho

Wir erzeugen ein Bild des Mondkraters auf einem *ImagePad,* importieren dessen Daten und legen mithilfe der Maus einen Schnitt durch das Bild. Die Datenwerte der Schnittlinie stellen wir auf einem *PlotPad* dar. Aus diesen und einigen Zusatzdaten können die Schattenlängen berechnet werden.

Darstellung des Kraterbildes auf dem ImagePad

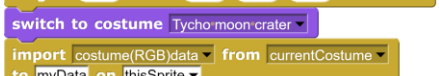

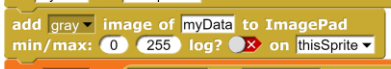

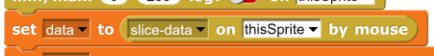

Datenaufnahme mit der Maus.

Umrechnung der RGB-Werte in Grauwerte

Datenkompression mit dem Faktor 5

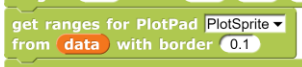

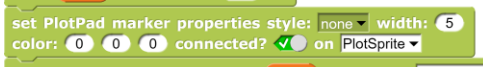

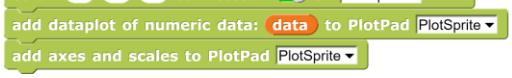

Erzeugung eines Diagramms auf einem zweiten Sprite, das als PlotPad konfiguriert wird.

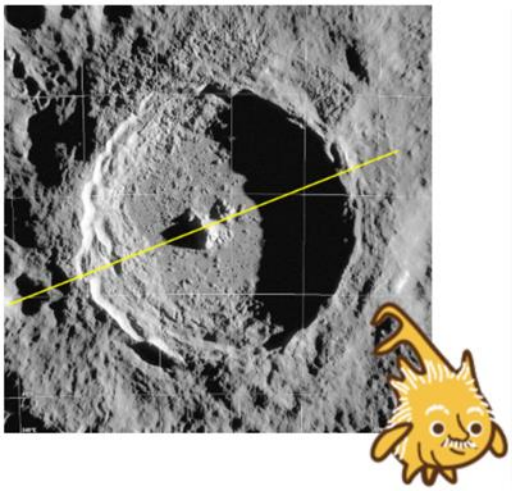

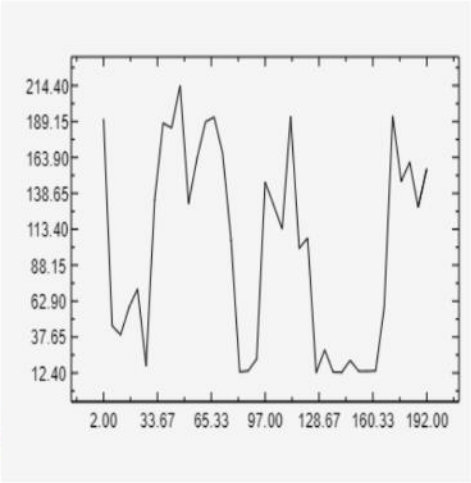

5.27 Darstellung gemischter Daten

Oft werden Textdaten mit numerischen Daten zusammengefasst. Ein Beispiel wären die Umsatzdaten verschiedener Vertreter in einem Jahr in einem Bereich. Wollen wir die grafisch darstellen, dann muss z. B. die x-Achse mit Textdaten beschriftet werden, während die y-Achse wie gehabt behandelt wird. Zum Erzeugen des Diagramms benutzen wir den Block *add dataplot of mixed data* des *PlotPads*. In diesem Fall soll die Bühne als *PlotPad* dienen.

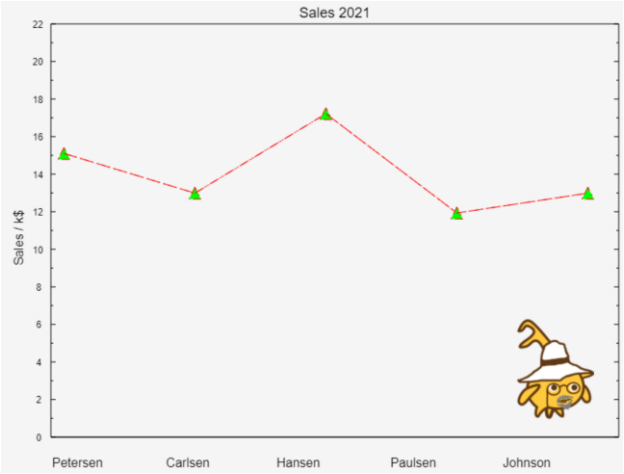

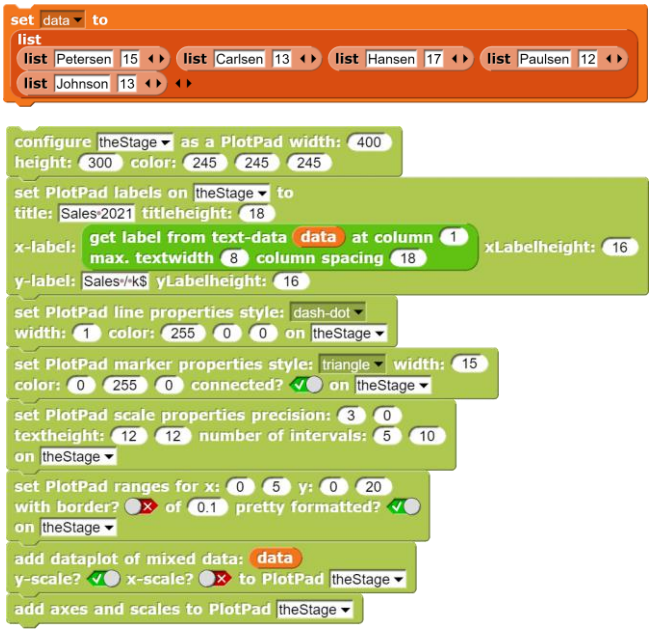

5.28 Eine einfache SQL-Abfrage

Als Beispiel wollen wir die Themen aller Englischkurse einer Schuldatenbank erfragen.

SQLData

22	A	B
1	Problems an	En 31
2	Problems an	En 32
3	Landeskund	en 31
4	Fantasy and	en 32
5	Fantasy and	en 33
6	Landscapes	En 41
7	Landscapes	En 42
8	Shakespeare	en 41
9	Education in	en 42
10	Education in	en 43
11	The Short St	En 11

5.29 Eine komplexere SQL-Abfrage

Anfrage an eine Schuldatenbank: Suche der besten Ergebnisse in Englisch

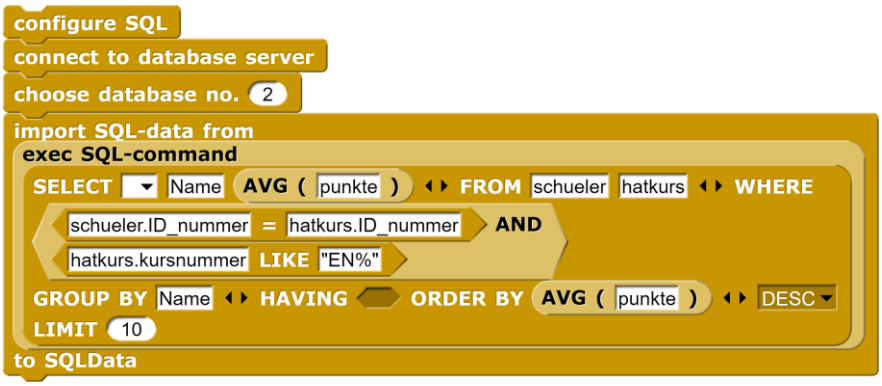

SQLData

10	A	B
1	Rassin	12.5000
2	Schmitt	12.5000
3	Wuchtig	12.2500
4	Frugich	12.0000
5	Knusel	12.0000
6	Pfaffner	11.7500
7	Zinn	11.7500
8	Reinsberg	11.5000
9	Krahn	11.2500
10	Tohler	11.2500

5.31 Umgang mit der SQL-Bibliothek

In der Praxis benötigt man dauernd die Details der Tabellen der benutzen Datenbank. Weist man nacheinander die Tabellen-Attribute einer Variablen zu und lässt diese mit *„open in dialog“* anzeigen, dann kann man die entsprechenden Tabellendaten geeignet im *SciSnap!*-Fenster platzieren und mit den Abfragen beginnen.

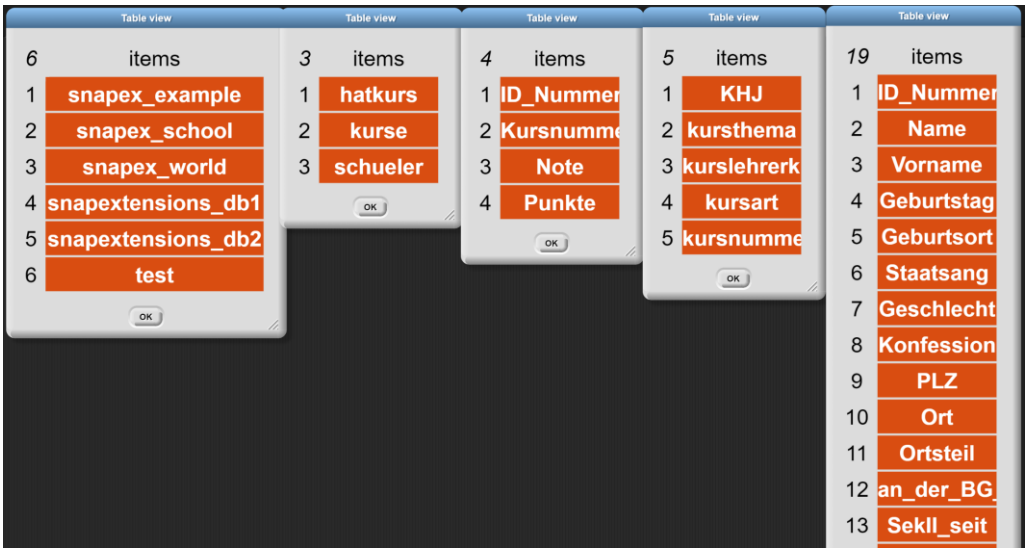

Beispiel: Die Kurstitel und Bewertung für alle Kurse eines Lernenden, absteigend sortiert nach der Note, werden gesucht.

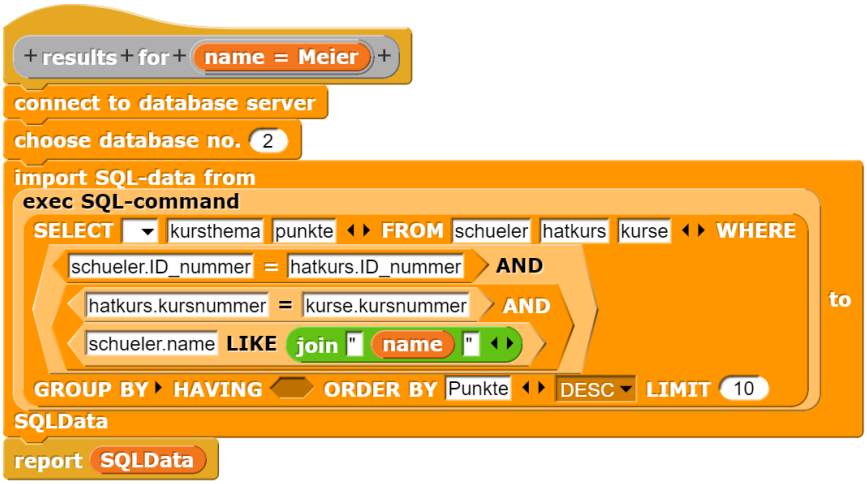

Beispiel: Für statistische Zwecke soll die ***schueler***-Tabelle nach unterschiedlichen Kriterien durchsucht werden können.

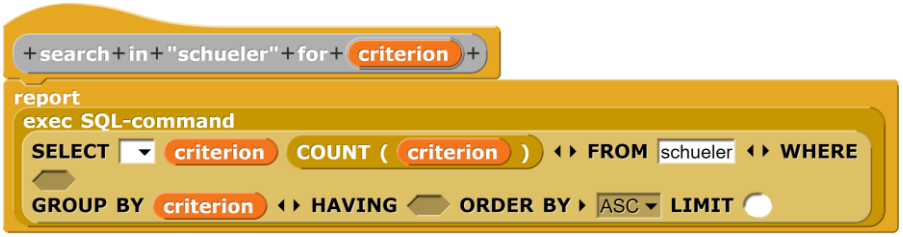

5.32 Einfache Zufallsgrafik

Wir zeichnen einfach 100 zufällig gewählte Grafikelemente übereinander.

```
configure thisSprite as an ImagePad width: 400
height: 300 color: 245 245 245
for i = 1 to 100
  set typ to pick random 1 to 6
  set r to pick random 0 to 255
  set g to pick random 0 to 255
  set b to pick random 0 to 255
  set ImagePad line properties style: continuous
  width: pick random 1 to 5 color: r g b
  fill color: r g b on thisSprite
  if typ = 1
    draw line from pick random 1 to 400 pick random 1 to 300 to
    pick random 1 to 400 pick random 1 to 300 on thisSprite
  if typ = 2
    draw rectangle from pick random 1 to 400
    pick random 1 to 300 to pick random 1 to 400
    pick random 1 to 300 on thisSprite
  if typ = 3
    fill rectangle from pick random 1 to 400 pick random 1 to 300
    to pick random 1 to 400 pick random 1 to 300 on thisSprite
  if typ = 4
    draw circle center: pick random 1 to 400 pick random 1 to 300
    radius: pick random 1 to 200 on thisSprite
  if typ = 5
    fill circle center: pick random 1 to 400 pick random 1 to 300
    radius: pick random 1 to 200 on thisSprite
  if typ = 6
    if pick random 1 to 2 = 1
      draw text Hello! at pick random 1 to 400 pick random 1 to 300
      height: pick random 1 to 100
      horizontal? on thisSprite
    else
      draw text Hello! at pick random 1 to 400 pick random 1 to 300
      height: pick random 1 to 100
      horizontal? on thisSprite
```

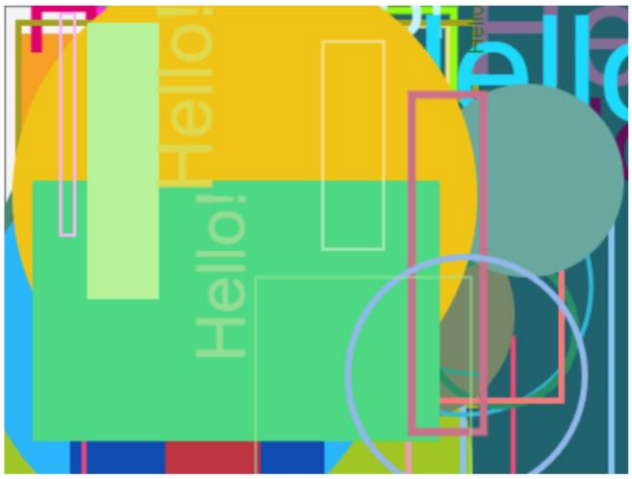

Aufgaben:

1. Suchen Sie im Netz nach Bildern von Piet Mondrian. Versuchen Sie, ähnliche Zufallsbilder auf dem *ImagePad* zu erzeugen.
2. Mithilfe eines „Fluchtpunktes“ lassen sich Bilder erzeugen, in denen sich Objekte scheinbar „von hinten nach vorne“ bewegen. Versuchen Sie es.

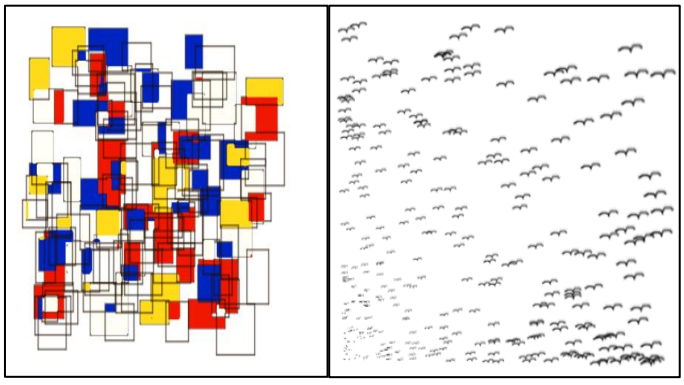

5.33 Falschfarbenbild eines Mondkraters

Wir importieren die Bilddaten aus einer FITS-Datei und stellen sie anschließend als Falschfarbenbild dar.

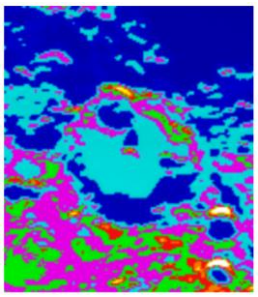

5.34 Schnitt durch ein Bild des Mondkraters Tycho

https://www.spektrum.de/fm/912/thumbnails/Mond0.jpg.2996657.jpg

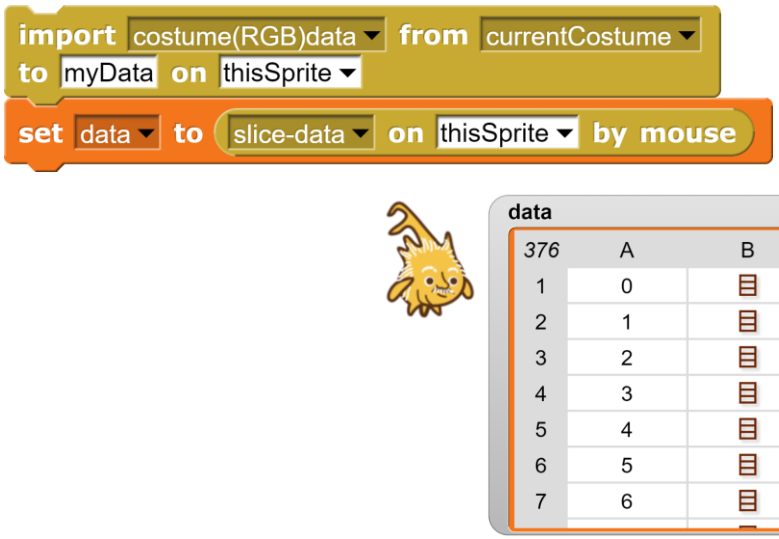

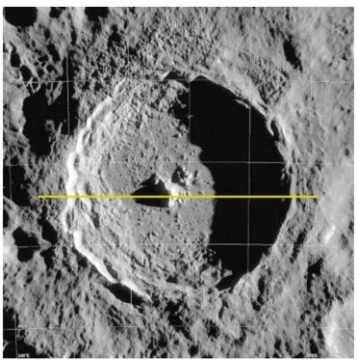

5.37 Darstellung von Bilddaten als Histogramm

Ein RGB-Bild wird geladen, in Graustufen zerlegt, und die normalisierte Verteilung der Bildwerte wird als Histogramm auf einem neuen *PlotPad* dargestellt. Das eigentliche Bild finden wir als Kostüm eines zusätzlichen Sprites namens „*ThePicture*“.

Zuerst einmal laden wir das Bild in den Datenbereich *SciSnap!Data*:

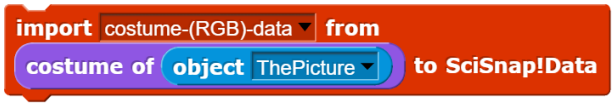

Wir erhalten 120.000 RBG-Werte.

Diese wandeln wir in Grauwerte um.

Danach wechseln wir zum *PlotSprite* und kopieren die geladenen Daten des *DataSprites*.

Jetzt können wir die Daten als Histogramm z. B. auf einem neuen *PlotPad* darstellen.

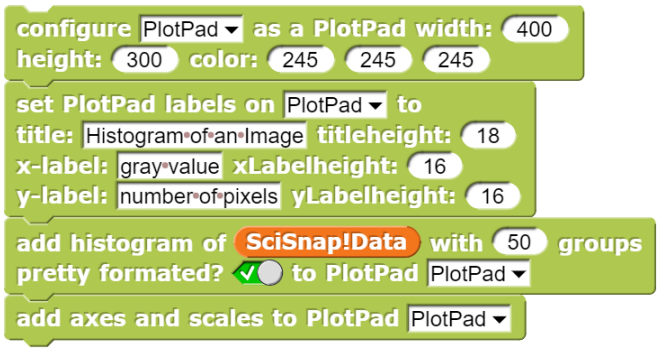

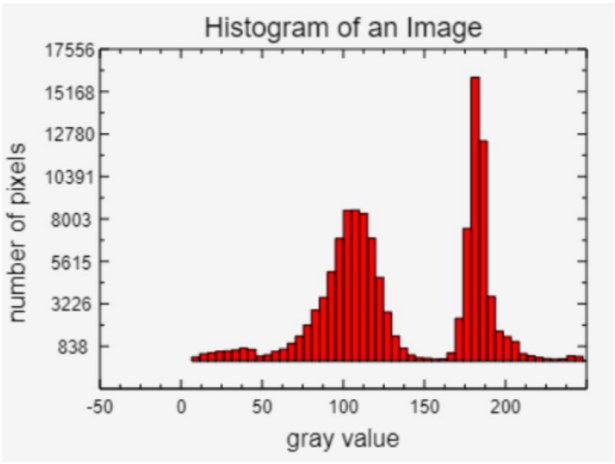

Aufgaben:

1. Suchen Sie im Netz unterschiedliche Datenmengen. Stellen Sie diese oder Teile von diesen grafisch dar.
2. Automatisieren Sie die Histogrammerstellung durch einen neuen Block ***histogram of*** *<costume>*. Vergleichen Sie die Histogramme typischer Bildtypen. Inwieweit ist ein Vergleich von Bildern auf diese Art möglich bzw. wo könnten Schwierigkeiten auftreten?
3. Stellen Sie im gleichen Diagramm die drei Farben eines RGB-Bildes durch Graphen und/oder Histogramme dar.

5.38 Simulation eines Planeten-Transits vor der Sonne

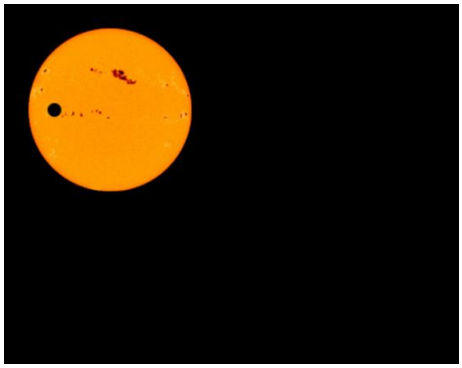

Wir suchen uns ein schönes Bild der Sonne (Quelle hier: [Schul-Astro]) und laden es als Kostüm eines Sprites. Damit es mehr nach Weltall aussieht, vergrößern wir die Bühne und färben sie schwarz. Zeichnen wir noch den Planeten, dann erhalten wir das nebenstehende Bild.

Der Planet soll als schwarzer Kreis vor der Sonne vorbeiziehen. Wenn wir einen solchen Kreis malen, dann verändern wir das eigentliche Sonnenbild. Von diesem ziehen wir deshalb eine Kopie *newCostume*, auf der wir dann zeichnen. Unser Planet soll sich von ganz links etwas außerhalb des Bildes (***x***=*-2r*) nach ganz rechts (***x***=*Bildbreite+2r*) auf der Höhe ***y*** bewegen. Auch den Radius ***r*** des Planeten können wir vorgeben.

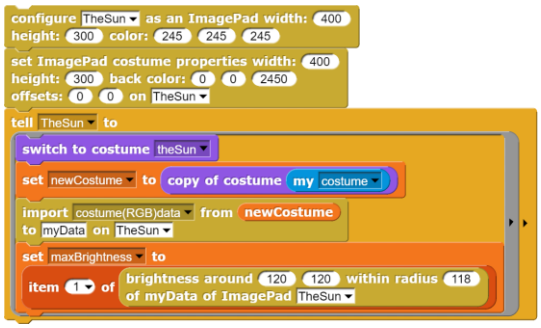

Die aktuelle Helligkeit dieser Anordnung können wir ohne allzu viele Kopiervorgänge bestimmen, indem wir von der anfangs bestimmten Gesamthelligkeit jeweils die Helligkeit der vom Planeten verdeckten Pixel abziehen. Dazu wird anfangs das Bild der Sonne in den Datenbereich *myData* importiert und die Helligkeit um den Bild-Mittelpunkt im Radius „halbe Bildbreite“ sowie die Anzahl der beteiligten Pixel bestimmt. *brightness around* liefert den summierten Grauwert sowie diese Anzahl. Aus diesen Größen berechnen wir jeweils die mittlere Helligkeit der „leicht verdunkelten“ Sonne und speichern sie zusammen mit der aktuellen Position in der Variablen *transitData*.

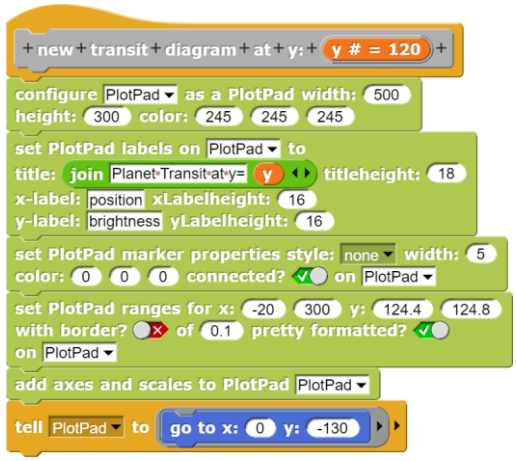

Parallel zum Transit soll ein Diagramm erstellt werden, in dem wir die Ergebnisse „live“ verfolgen können. Dazu erzeugen wir ein weiteres Sprite, das wir *PlotPad* nennen und das wir entsprechend konfigurieren. Die dafür erforderlichen Befehle verpacken wir in einem Block namens *new transit diagram*.

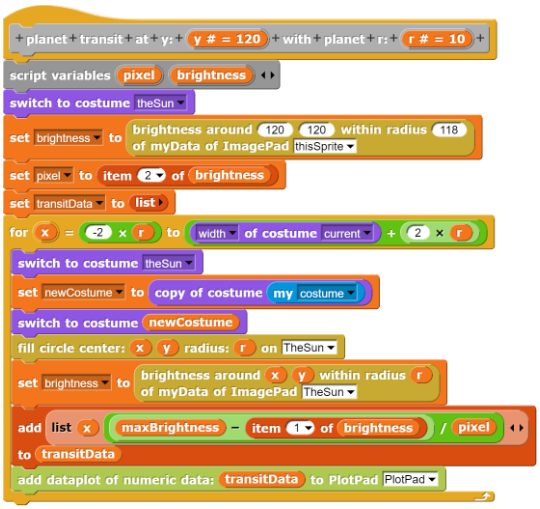

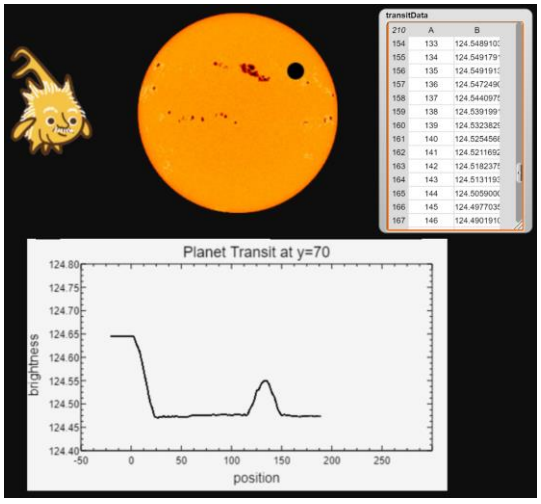

Danach schreiben wir einen Block, der die Helligkeitsdaten wie beschrieben ermittelt und parallel das Diagramm auffrischt. Das Ergebnis entspricht in etwa einer der Methoden, mit denen Exo-Planeten gefunden werden.

5.39 Affine Transformation eines Bildes

In der *SciSnap!ImagePadLibrary* finden wir einen Block, der es gestattet, affine Transformationen in einem Bild vorzunehmen, indem man drei Punkte auf drei andere abbildet – und alle anderen Punkte entsprechend. Als Bild wird das aktuelle Kostüm eines Sprites genommen.

Wir wollen wir ein Bild an der Mittellinie vertikal spiegeln. Wir laden das Bild – hier: einer Kirche – und wählen dazu entsprechende Punkte an den Rändern aus. Diese fassen sie zu den beiden Listen *source* und *target* zusammen.

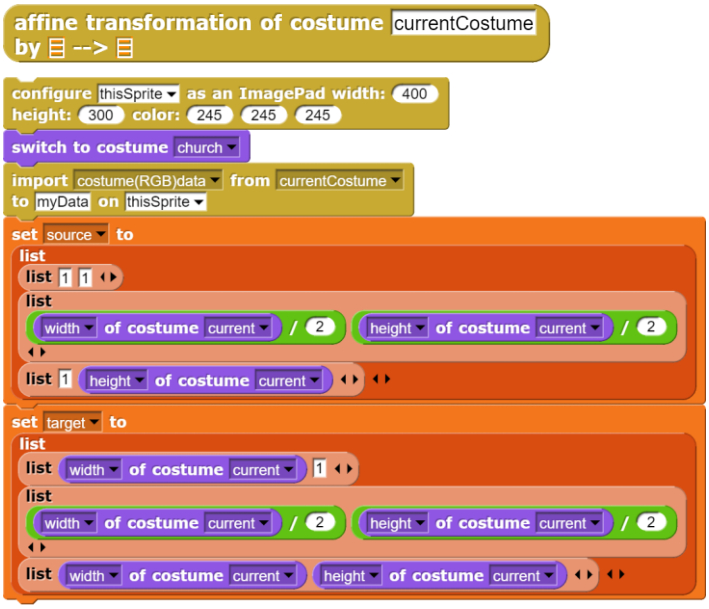

Zuletzt erzeugen wir ein Duplikat des *ImagePads* und bitten dieses, das transformierte Bild als Kostüm anzuzeigen.

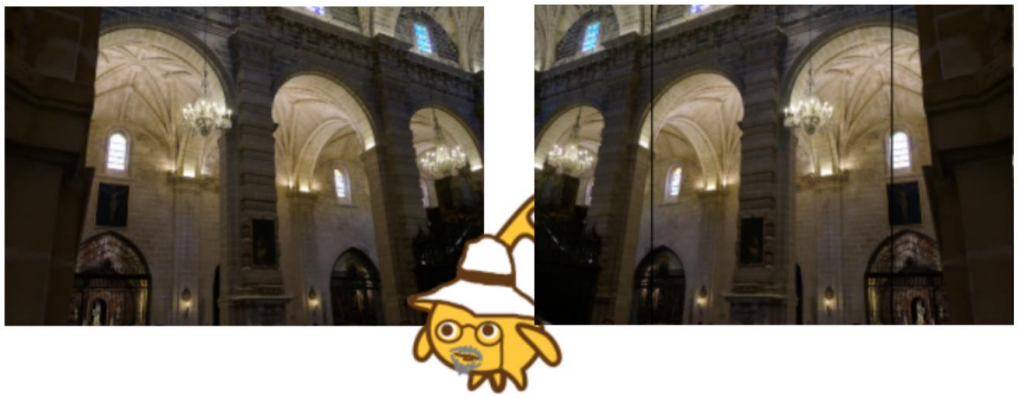

5.40 Kernel-Anwendung zur Kantenerkennung

Wir konfigurieren ein Sprite als *ImagePad* und wechseln zum Kostüm eines antiken Tempels. Dieses Bild importieren wir in den Datenbereich *myData* des *ImagePads*.

Auf diese Bilddaten wenden wir den *Laplace*-Kernel $\begin{bmatrix} 1 & 1 & 1 \\ 1 & -8 & 1 \\ 1 & 1 & 1 \end{bmatrix}$ mithilfe des Blocks an *convolution kernel applied* … der *SciSnap!DataLibrary* und speichern das Ergebnis in der Variablen *data*. Das Ergebnis zeigen wir als neues Kostüm an. Zum Vergleich stellt ein zweites Sprite das Originalbild dar.

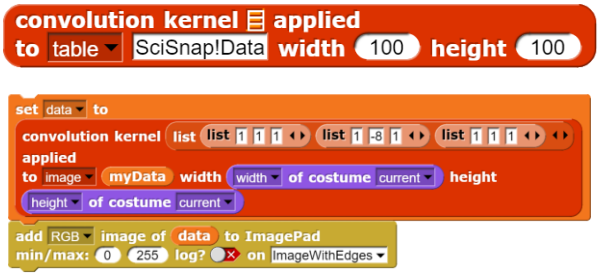

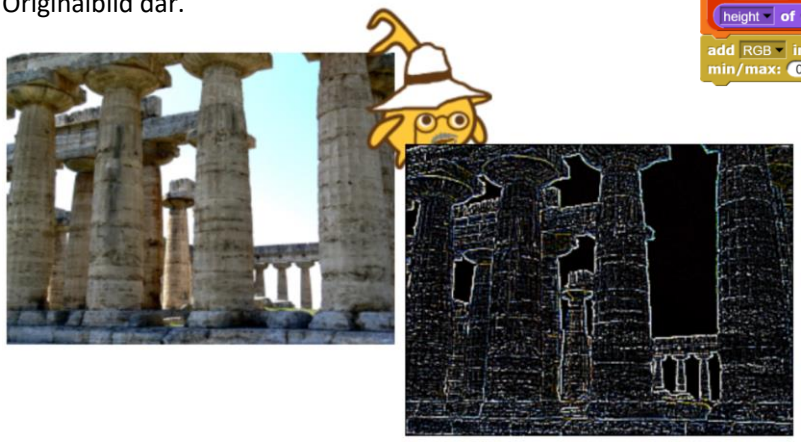

Aufgaben:

1. Bilder sind manchmal etwas „flau“. Das liegt daran, dass sie nicht den vollen Wertebereich für die drei Farbkanäle von 0 bis 255 ausnutzen.
   a: Entwickeln Sie eine Methode, die Wertebereiche eines Bildes zu ermitteln und anzeigen zu lassen.
   b: Entwickeln Sie eine Methode; den vollen Wertebereich auszuschöpfen, also schwarze Pixel auf 0, helle auf 255 abzubilden.
   c: Fassen Sie das Verfahren in einem neuen Block zusammen, dem das Kostüm eines Sprites übergeben wird und der das verbesserte Kostüm als Ergebnis zurückgibt.

2. a: Auf Bildern kann man versuchen, „Gesichter“ zu finden, indem man zusammenhängende Bereiche eines Farbbereichs, z. B. „orange“, hervorhebt und den Rest des Bildes löscht. Versuchen Sie, dafür einen neuen Block zu entwickeln.
   b: Mithilfe eines Kernels können die Ränder solcher Bereiche isoliert werden. Informieren Sie sich z. B. im Netz über geeignete Kernels und erproben Sie diese bzgl. des genannten Zwecks.
   c: Gesichter sind oft „oval“. Versuchen Sie auf diesem Wege Gesichter von anderen „orangenen“ Gegenständen zu unterscheiden.

3. a: Richtig künstlerische Fotos sind natürlich schwarz-weiß. Wenn man keine hat, kann man aus RGB-Bildern Graustufenbilder erzeugen. Tun Sie das.
   b: Noch künstlerischer wirkt es, wenn die Fotos „hart“ sind, also einen sehr starken Kontrast haben. Experimentieren Sie mal ein bisschen!

5.41 Mittlerer Abstand in einem Random-Graph (Small Worlds)

Wir berechnen den mittleren Abstand der Knoten in einem Graphen, bei dem zuerst alle Knoten und danach alle Kanten erzeugt wurden.

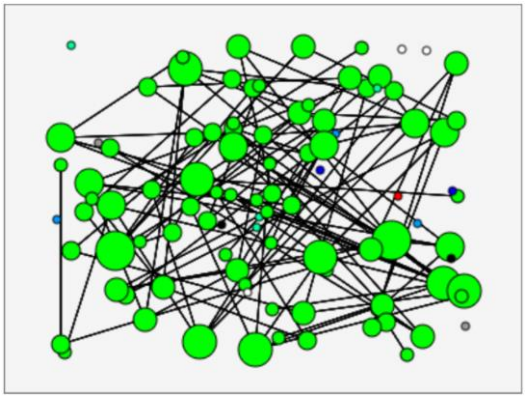

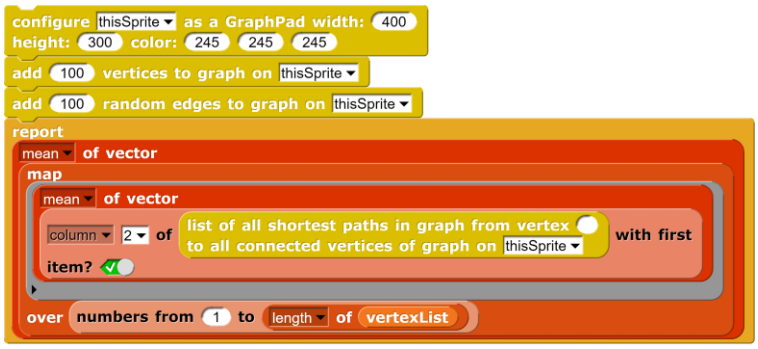

5.42 Mittlerer Abstand in einem Scalefree-Graph (Small Worlds)

Wir berechnen den mittleren Abstand der Knoten in einem Graphen, bei dem abwechselnd Knoten und Kanten erzeugt wurden.

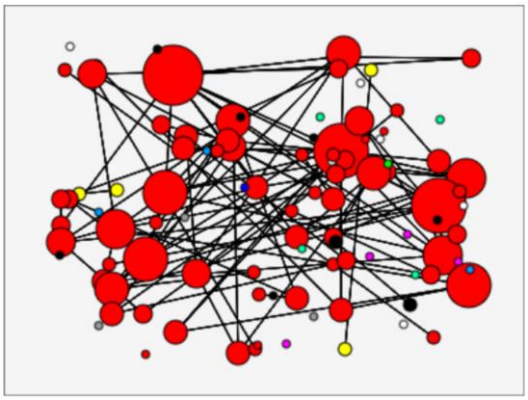

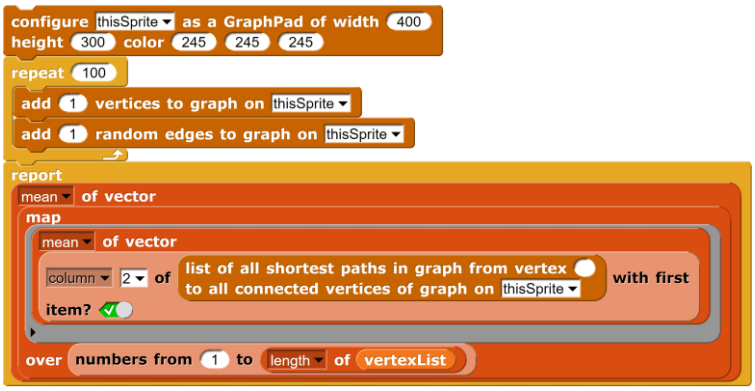

5.43 Histogramm „Kanten pro Knoten“ in einem Random-Graph

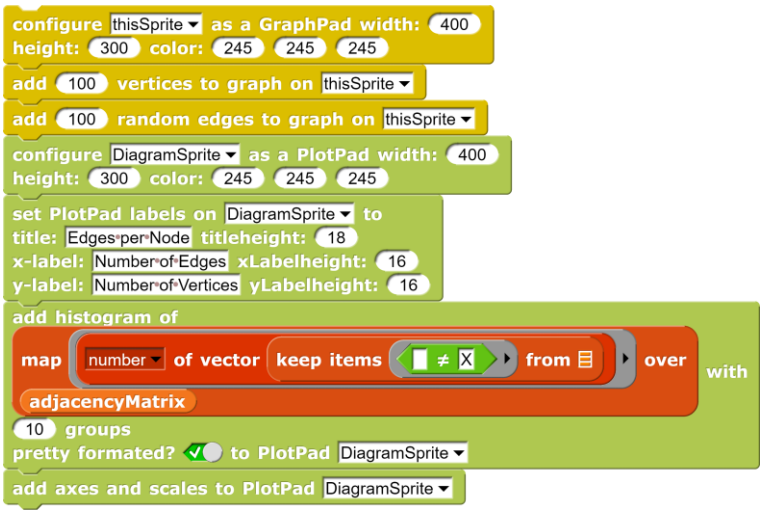

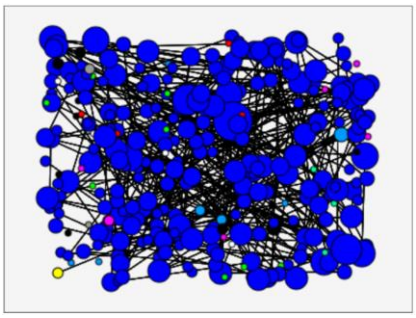

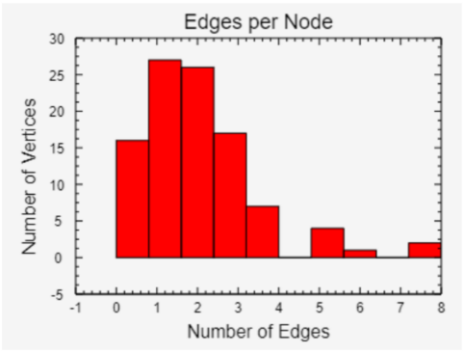

5.44 Histogramm „Kanten pro Knoten“ in einem Scalefree-Graph

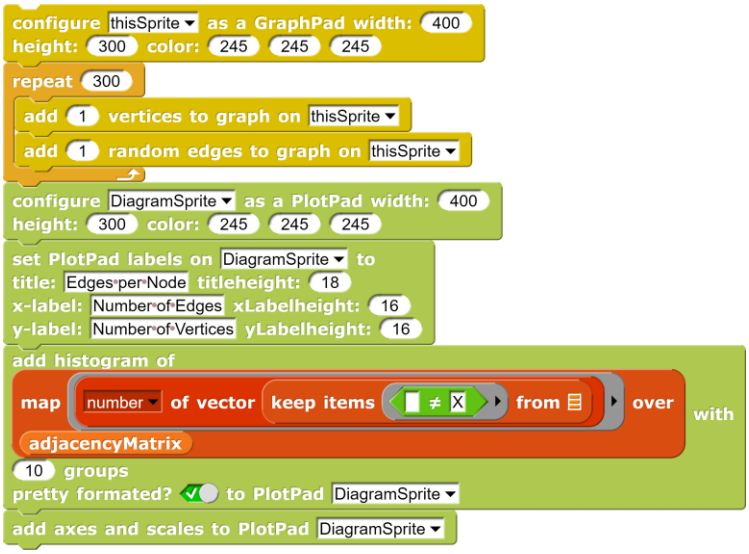

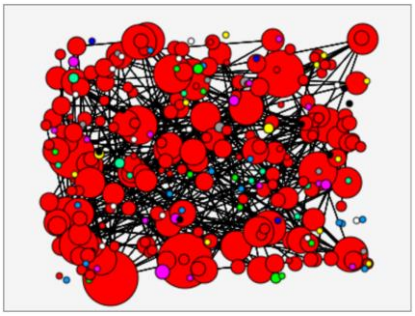

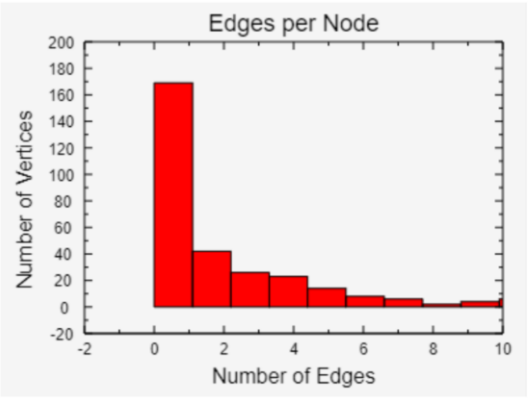

5.45 Breiten- und Tiefensuche im Stammbaum

Wir erzeugen einen Stammbaum als gerichteten Graphen ohne Kantengewichte einfach durch Anordnung und Verbindung der entsprechenden Knoten. Das ist umständlich, aber einfach. Eben etwas Gefummel.

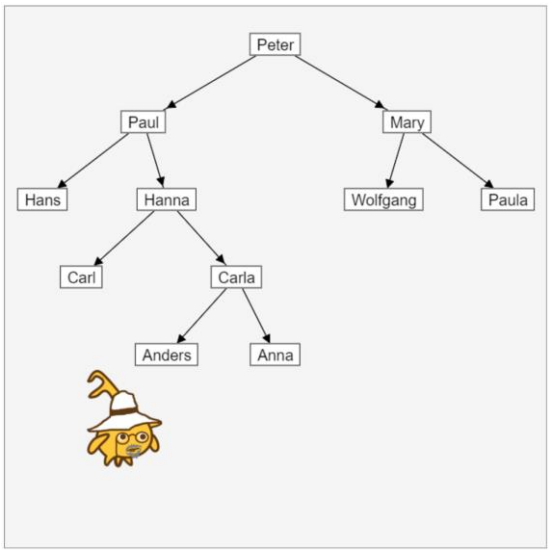


```
+ new + family + tree +
configure FamilyTree as a GraphPad width: 700 height: 700 color: 245 245 245
set GraphPad vertex properties minSize: 10 growing? showsContent? on FamilyTree
set GraphPad edge properties lineWidth: 1 color: 0 0 0 directed? weighted? showsWeight? on FamilyTree
new vertex at 0 300 content: Peter on graph of FamilyTree
new vertex at -170 200 content: Paul on graph of FamilyTree
add edge from vertex 1 to vertex 2 to graph on FamilyTree
new vertex at 170 200 content: Mary on graph of FamilyTree
add edge from vertex 1 to vertex 3 to graph on FamilyTree
new vertex at -300 100 content: Hans on graph of FamilyTree
add edge from vertex 2 to vertex 4 to graph on FamilyTree
new vertex at -140 100 content: Hanna on graph of FamilyTree
add edge from vertex 2 to vertex 5 to graph on FamilyTree
new vertex at 140 100 content: Wolfgang on graph of FamilyTree
add edge from vertex 3 to vertex 6 to graph on FamilyTree
new vertex at 300 100 content: Paula on graph of FamilyTree
add edge from vertex 3 to vertex 7 to graph on FamilyTree
new vertex at -250 0 content: Carl on graph of FamilyTree
add edge from vertex 5 to vertex 8 to graph on FamilyTree
new vertex at -50 0 content: Carla on graph of FamilyTree
add edge from vertex 5 to vertex 9 to graph on FamilyTree
new vertex at -140 -100 content: Anders on graph of FamilyTree
add edge from vertex 9 to vertex 10 to graph on FamilyTree
new vertex at 0 -100 content: Anna on graph of FamilyTree
add edge from vertex 9 to vertex 11 to graph on FamilyTree
```

In diesem Baum können wir nun alle möglichen Aufgaben lösen. Wir könnten z. B. fragen, ob eine Person Vorfahr von einer anderen ist. Dazu benötigen wir die Nummer des Startknotens, die wir mit `vertexnumber of Peter in graph of FamilyTree` ermitteln. Den Rest erledigt entweder der Block zur Breitensuche oder der zur Tiefensuche.

```
+ is + parent = Carla + ancestor + of + child = Mary + ? +
script variables result
set result to
    breadth first search of content parent
    starting at vertex vertexnumber of child in graph of FamilyTree of graph
    on FamilyTree
draw graph on FamilyTree
report result
```

```
is Carla ancestor of Peter ?
```

Bei der Breiten- und Tiefensuche werden die besuchten Knoten markiert und bei einem erneuten Zeichnen des Graphen rot dargestellt. Das zeigt die Unterschiede der beiden Suchverfahren ziemlich deutlich.

Tiefensuche

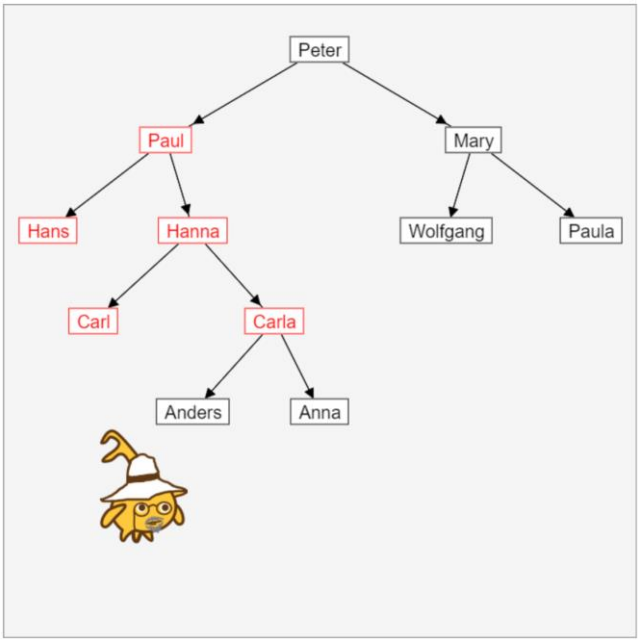

Breitensuche

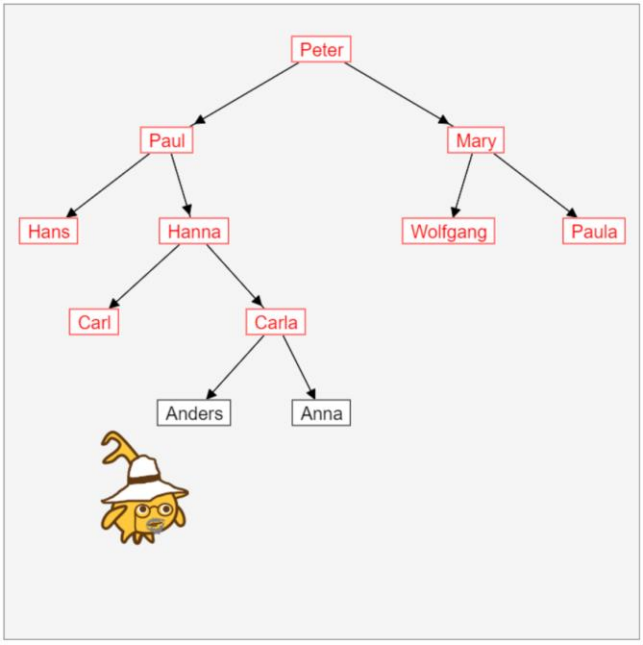

Aufgaben:

1. Ermitteln Sie, über wie viele Generationen die Verwandtschaft besteht, wenn sie denn besteht.
2. Stellen Sie Listen von Verwandten einer Person auf, z. B. von Eltern, Großeltern, Tanten, Schwippschwagern 😉, …
3. a: Entwickeln Sie ein Skript zur Erstellung eines Entscheidungsbaums, z. B. zur Klassifikation von Tieren oder Pflanzen: Es wird jeweils gefragt, ob es sich um ein bestimmtes Exemplar handelt oder, falls nicht, durch welche Frage man das genannte von dem aktuellen unterscheiden kann („Hat es vier Beine?“). Es wird entweder das Exemplar oder die Frage in den Baum eingetragen.

   b: Lassen Sie ihr Ergebnis von anderen testen. Versuchen Sie abzuschätzen, ab welcher Datenmenge im Baum so ein Programm sinnvoll einsetzbar wäre.

   c: Entscheidungsbäume spielen eine Rolle bei den bestimmten Anwendungen des maschinellen Lernens (*Decision Tree Classification*). Informieren Sie sich über das Verfahren und seine Einsatzgebiete.

5.46 Ein einfaches Perzeptron als Graph

Wir wollen *Hilberto* bitten, ein *GraphPad* zu benutzen, um die Funktionsweise eines einfachen Perzeptrons zu veranschaulichen. Dazu soll er drei Eingabeknoten links im Bild platzieren. in der Mitte sitzt das eigentliche Perzeptron mit einer Sprungfunktion, das entweder +1 oder -1 an das Ausgabeneuron rechts im Bild übermittelt. Insgesamt handelt es sich also um einen *gerichteten Graphen* mit *Kantengewichten*. Den richtet *Hilberto* schnell ein: er erzeugt ein neues Sprite namens *Perceptron* und konfiguriert es richtig.

```
Click on input neurons!
```

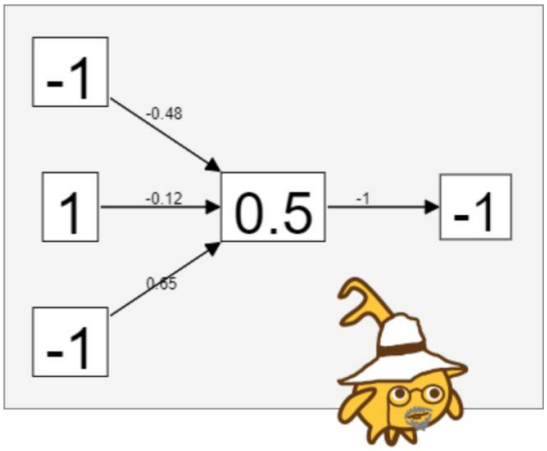

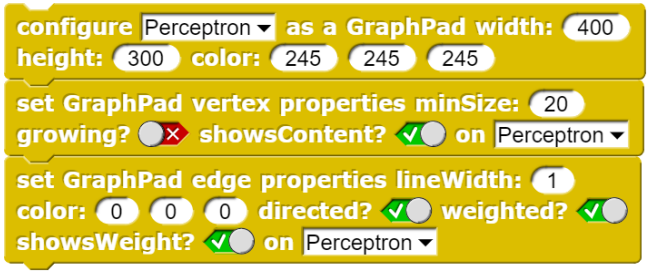

Danach fügt er angegebenen Knoten des Perzeptronnetzes hinzu:

Es fehlen nur noch die Kanten, zuerst mit zufälligen Gewichten:

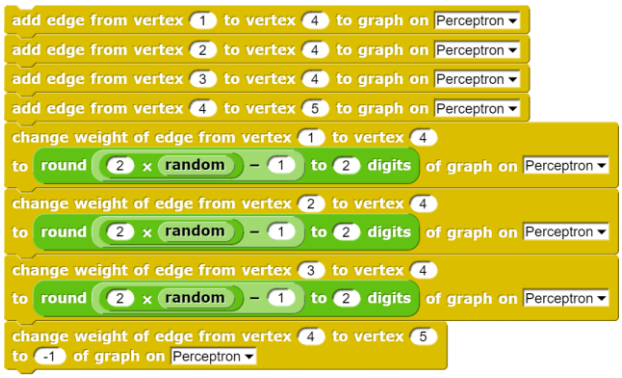

Hilberto fügt die Blöcke zu einem Skript zusammen und beschriftet das Ganze, und natürlich sorgt er für eine konsistente Situation, indem er das Perzeptron einmal durchrechnen lässt.

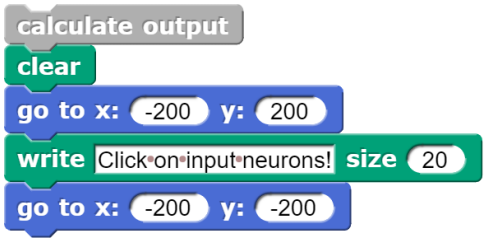

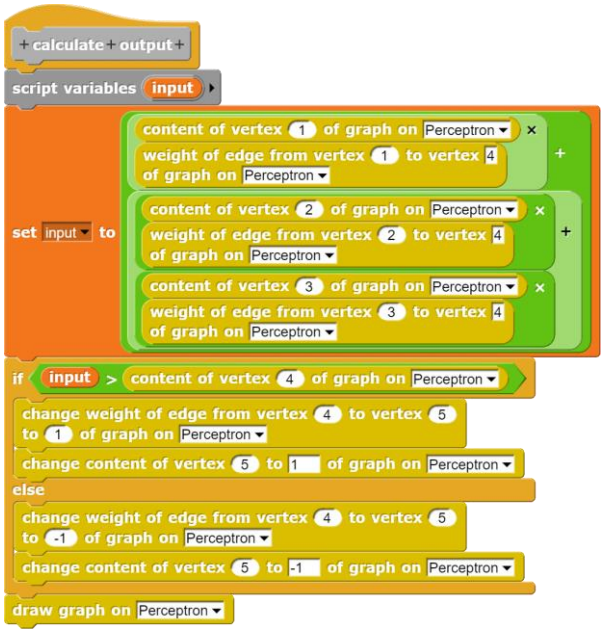

Die Ausgabe des Netzes wird bestimmt, indem die Werte der Eingabeneuronen mit den entsprechenden Kantengewichten multipliziert und die Ergebnisse addiert werden. Das Resultat wird dann mit dem Wert der Sprungfunktion in Neuron 4 verglichen. Je nach Ergebnis wird der Wert der letzten Kante und der Wert des Ausgabeneurons gesetzt.

Allerdings soll das Perzeptron auch noch arbeiten, und zwar auf folgende Weise: wenn ein Eingabe-Neuron, also ein Knoten auf der linken Seite, angeklickt wird, dann soll er seinen Wert ändern. Wir rechnen dazu die Mauskoordinaten beim Klick in Sprite-Koordinaten um und fragen anschließend nach der Knotennummer. Ist es eine der drei Eingabeneuronen, dann ändern wir deren Wert – und lassen neu rechnen.

Fertig.

Hilberto ist selbst erstaunt, dass das so einfach geht. 😉

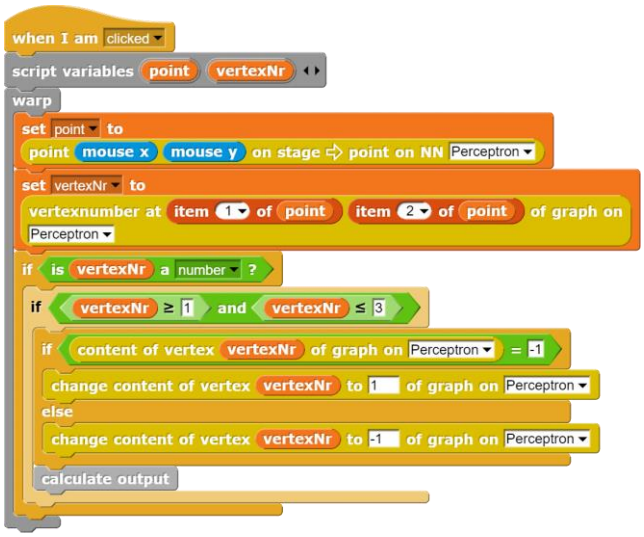

<u>Aufgaben</u>:

1. Ergänzen Sie eine Möglichkeit, den Wert der Sprungfunktion des zentralen Neurons zu ändern.
2. Ergänzen Sie eine Möglichkeit, die Kantengewichte der drei Eingabeneuronen zum zentralen Neuron zu ändern.
3. Ändern Sie die Kantengewichte und/oder die Sprungfunktion so, dass das Perzeptron als UND arbeitet.
4. Ändern Sie die Kantengewichte und/oder die Sprungfunktion so, dass das Perzeptron als ODER arbeitet.
5. Ändern Sie die Kantengewichte und/oder die Sprungfunktion so, dass das Perzeptron als NAND arbeitet.
6. Ändern Sie die Kantengewichte und/oder die Sprungfunktion so, dass das Perzeptron als NOR arbeitet.
7. Kann das Perzeptron auch als XOR arbeiten? Probieren Sie es aus!
8. Suchen Sie in der Literatur Gründe, weshalb sich einige Schaltungen gut durch Perzeptrons realisieren lassen, und andere nicht.

5.47 Ein einfaches lernendes Perzeptron

Wir ändern jetzt die Konfiguration ein wenig, um dem Perzeptron das Lernen beizubringen. Dazu führen wir einen weiten Knoten, einen „Zielknoten“, unter dem Ausgabeknoten ein, der „die richtigen“ Ergebnisse anzeigt, die wiederum durch Anklicken geändert werden können. Zeigt sich ein Unterschied zwischen den Werten von Ausgabe- und Zielknoten, dann werden die Gewichte solange geändert, bis sich das „richtige“ Ergebnis ergibt.

Was ist zu ändern?

Bei der Erzeugung des Netzes muss nur der neue Knoten eingefügt werden.

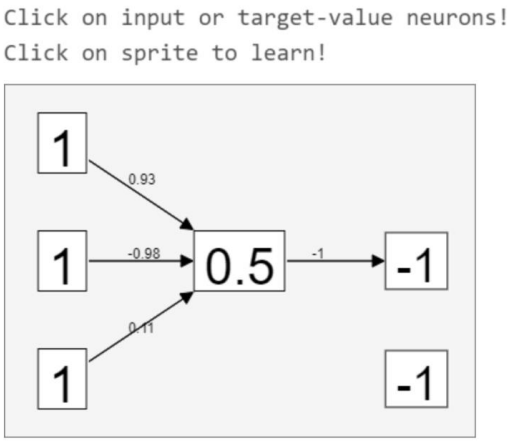

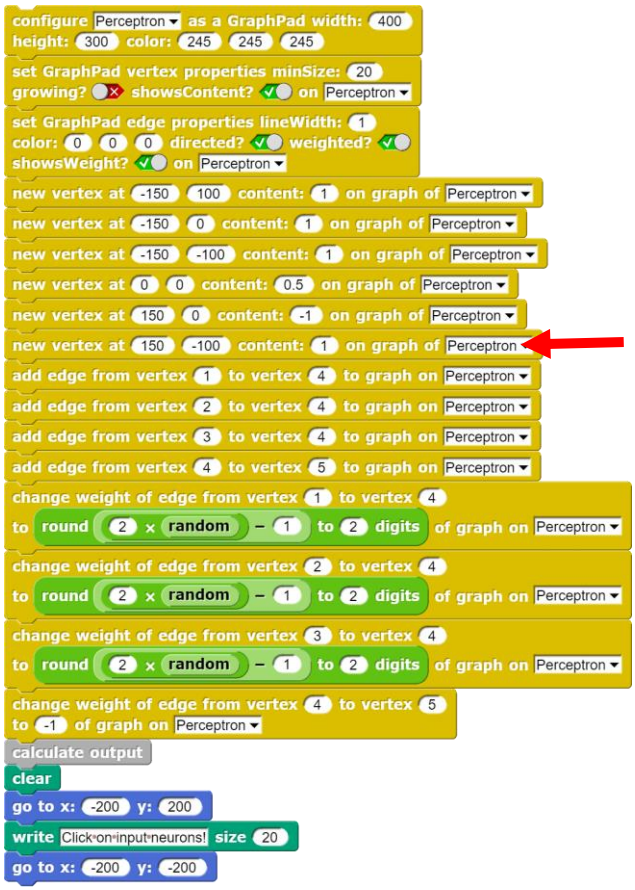

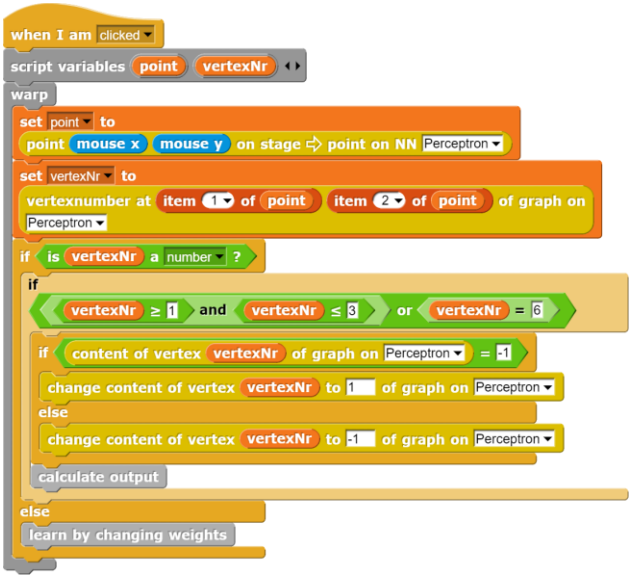

Und beim Klick-Ereignis auf das *GraphPad* muss nachgesehen werden, ob ein Knoten oder das Pad getroffen wurde. Im zweiten Fall startet das Lernen.

Und wie wird gelernt?

Wenn sich die Werte der beiden Neuronen rechts im Bild unterscheiden, dann ändern wir die Gewichte an den Kanten der Eingabeneuronen solange, bis sich das richtige Ergebnis ergibt.

Genauer: Wir geben den drei Eingabeneuronen jeweils einen Wert. Danach stellen wir den gewünschten Wert am Zielneuron ebenfalls durch Anklicken ein. Zuletzt klicken wir irgendwo auf das GraphPad und sehen ihm beim Lernen zu.

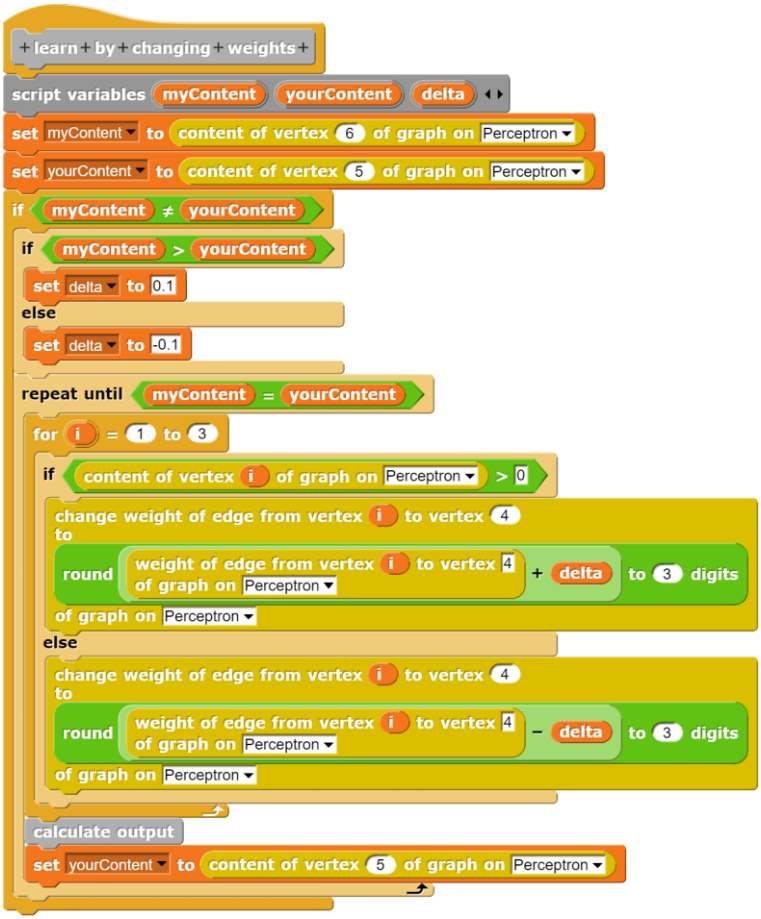

Aufgaben:

1. Ergänzen Sie eine Möglichkeit, das Lernen durch Änderungen am Wert der Sprungfunktion im inneren Neuron zu realisieren. Klappt das auch immer?
3. Trainieren Sie das Netz so, dass das Perzeptron als UND arbeitet.
4. Trainieren Sie das Netz so, dass das Perzeptron als ODER arbeitet.
5. Trainieren Sie das Netz so, dass das Perzeptron als NAND arbeitet.
6. Trainieren Sie das Netz so, dass das Perzeptron als NOR arbeitet.
7. Kann das Perzeptron auch als XOR arbeiten? Probieren Sie es aus!

5.48 Training eines Neuronalen Netzes

Ein Neuronales Netz des Breite 4 mit zwei Schichten (plus Eingabeschicht) wird erzeugt und darauf trainiert, bei Eingabe des Vektors aus den Zahlen 1 bis 4 als Ausgabe links eine 1 und rechts eine -1, dazwischen Nullen, zu liefern. Zu beachten ist, dass nicht die exakten Ausgabewerte, sondern links der größte und rechts der kleinste geliefert werden müssen.

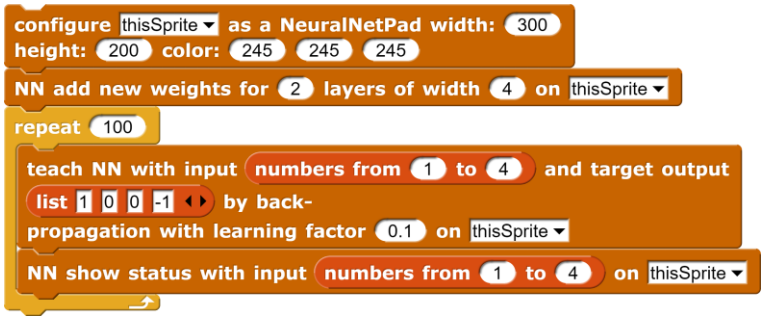

Die Ausgabe des Netzes vor dem Training:

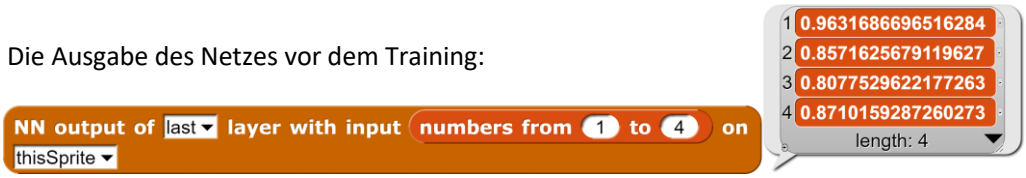

Trainingszustände nach jeweils 20 Trainingsschritten:

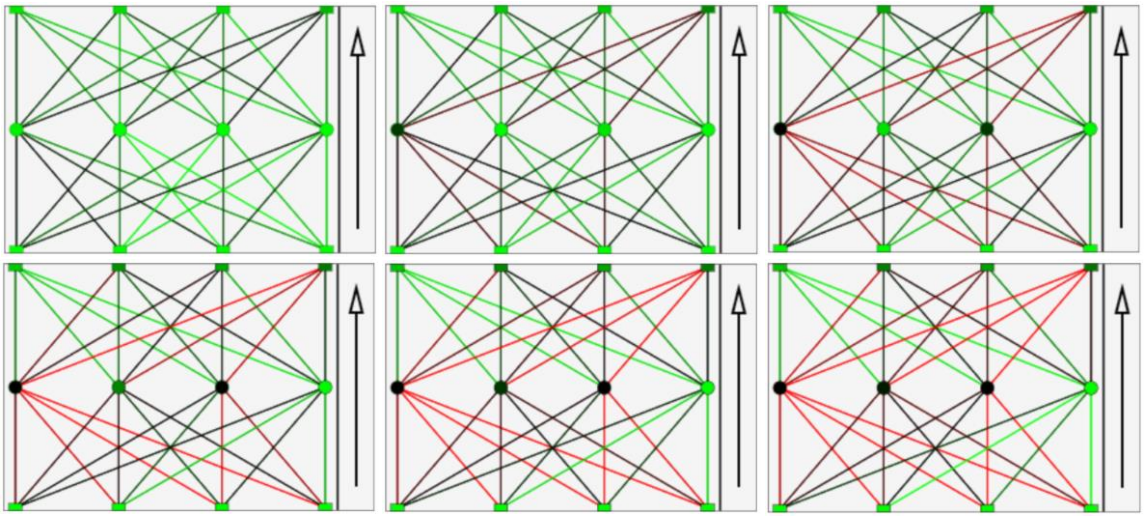

Die Ausgabe des Netzes nach dem Training:

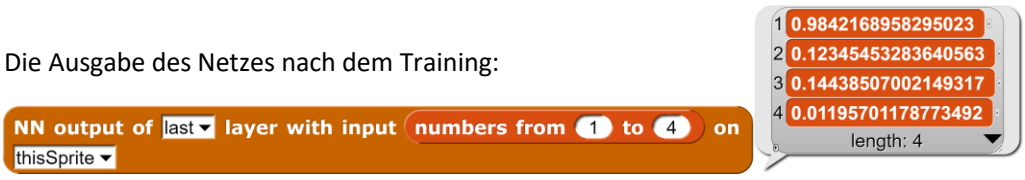

Die Positionen des größten bzw. kleinsten Werts der Ausgabe können direkt mithilfe der *SciSnap!DataLibrary* bestimmt werden:

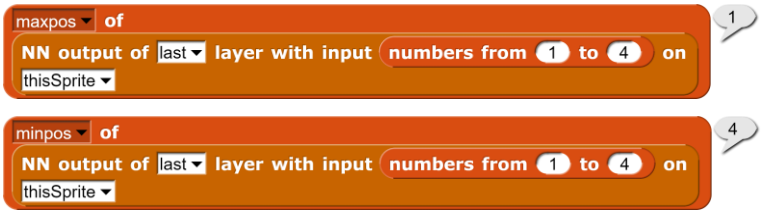

5.49 Verkehrszeichenerkennung mit einem Neuronalen Netz von Perzeptrons

„Tiefe“ Neuronale Netze prägen die Diskussion über die aktuelle „künstliche Intelligenz“. Dabei handelt es sich meist um „fully connected“ Netze aus mehreren Perzeptron-Schichten. „Fully connected“ bedeutet, dass alle Neuronen einer Schicht mit allen der nächsten Schicht verbunden sind. Jede Verbindung ist mit einem Gewicht versehen, aus dem sich sein Einfluss auf das verbundene Perzeptron ergibt – aber das lesen Sie besser woanders nach.

Betrachten wir dazu einmal ein Netz aus drei Lagen, das als Eingabe die Pixel eines aktuellen 20 M-Pixel-Fotos erhält, also $2x10^7$ Pixel. Die Eingabeschicht besteht aus $3x2x10^7$ MB Zahlenwerten zwischen 0 und 255 (wenn wir das Transparenz-Byte weglassen). Zur nächsten Schicht gibt es dann $(6x10^7)^2=3,6x10^{15}$ Verbindungen – und das dann noch zweimal. Insgesamt wären $3x3,6x10^{15}$, also etwa 10^{16} Gewichte zu bestimmen – eine für „normale“ Rechner völlig utopische Aufgabe. Wir werden uns also auf etwas kleinere Neuronale Netze beschränken müssen.

Eine Möglichkeit, Perzeptron-Netze zu trainieren, besteht darin, ihnen Eingabevektoren zu präsentieren und die gewünschte Ausgabe gleich dazu. Das Netz berechnet dann die Ausgabe, die sich aus den vorhandenen, anfangs zufällig gewählten Gewichten ergibt, und bestimmt die Differenz zum vorgegebenen Ergebnis. Von der letzten Ergebnisschicht ausgehend korrigiert es dann die Gewichte „rückwärtsgehend“ so, dass seine Ausgabe „etwas besser“ zum vorgegebenen Ergebnis passt. Das Verfahren nennt sich *Backpropagation*. Auch hierzu sollten Sie sich an anderer Stelle informieren. Aus vielen solcher Korrekturen ergibt sich das trainierte Netz. „Lernen“ bedeutet also, anhand vieler Beispiele die Parameter (die Gewichte) anzupassen. Mithilfe dieser Parameter bestimmt das Netz aus dem Eingabevektor einen Ausgabevektor: es berechnet einen Funktionswert. Unser *NeuralNetPad* kann solche Perzeptron-Netze simulieren und trainieren.

Die Gewichte bilden insgesamt einen *Tensor* mit *m* Schichten, die aus *nxn-Matrizen* bestehen. *NeuralNetPads* sollten deshalb die lineare Algebra beherrschen. Neu ist nur die *Softmax*-Funktion 

, mit der man z. B. Eingabevektoren skalieren kann. Auch hierzu sollten Sie sich informieren.

Die Dimensionierung und Anfangsbelegung des Netzes erfolgen im Block *add new weights*. Mit diesem Block können wir ein neues Neuronales Netz beliebiger Größe mit zufälligen Anfangsgewichten erzeugen. In diesem Fall hat es die Breite 3 und die Tiefe 2.

Da die Anzeige der vielen Zahlen ziemlich unübersichtlich und auch kaum informativ wäre, werden die Verbindungslinien (die *Kanten*) entsprechend den Werten der zugehörigen Gewichte farbcodiert: von vollem Grün für große positive Werte über Schwarz für kleine Beträge hin zu roten negativen Gewichten. Da anfangs nur positive Zahlen per Zufallsgenerator gezogen werden, ist ein neues Netz überwiegend grün. Es zeigt an, was sich aus den Berechnungen mit dem anzugebenden Eingabevektor ergibt.

Die *Knoten* des Netzes werden wie die Kanten farbkodiert. Unten stehen die Elemente des Eingabevektors als kleine Rechtecke. Die inneren Schichten bilden farbige Kreise und die letzte Schicht wird als Ausgabeschicht wieder rechteckig dargestellt. Die Richtung der Berechnung von unten nach oben zeigt der Pfeil ganz rechts. Da man Sprites aber einfach drehen kann, kann die Richtung natürlich auch anders dargestellt werden.

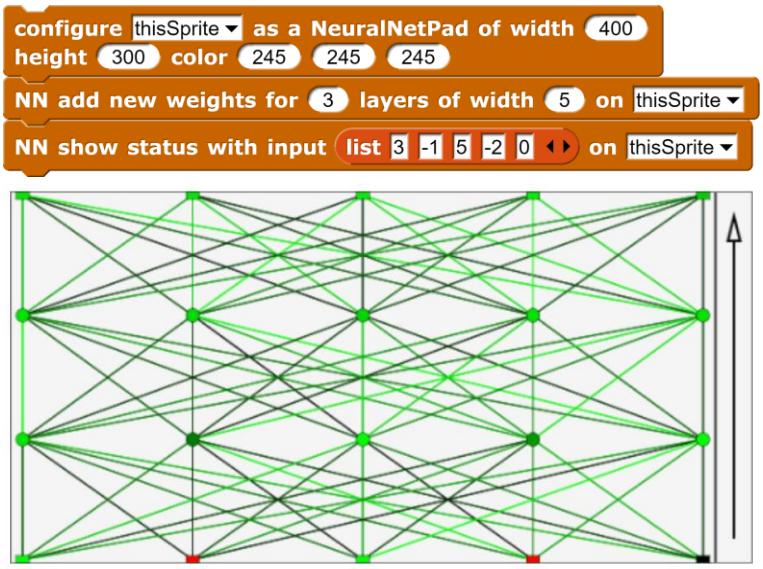

Oft benötigt man die Ergebnisse der letzten oder auch einer inneren Schicht des Netzes. Die können mithilfe des Blocks *output of…* bei vorgegebener Eingabe berechnet werden. Da die Farbcodierung nicht unbedingt das größte oder kleinste Element klar anzeigt, kann dieses mithilfe des *…of vector…*-Blocks bestimmt werden.

Das Training des Netzes erfolgt mithilfe des Blocks *teach NN …* durch Backpropagation mit einem anzugebenden Lernfaktor. Der darf anfangs durchaus etwas größer sein, um dann verkleinert zu werden.

Wir wollen ein neuronales Netz (NN) so trainieren, dass es 12 unterschiedliche Verkehrszeichen erkennt. Dazu suchen wir Bilder von diesen Verkehrszeichen im Netz und verkleinern sie auf das Format 100 x 100 Pixel. Man kann sie jetzt zwar gut am Bildschirm darstellen, aber die 10000 Pixel sind als Eingänge für ein NN natürlich viel zu viel.

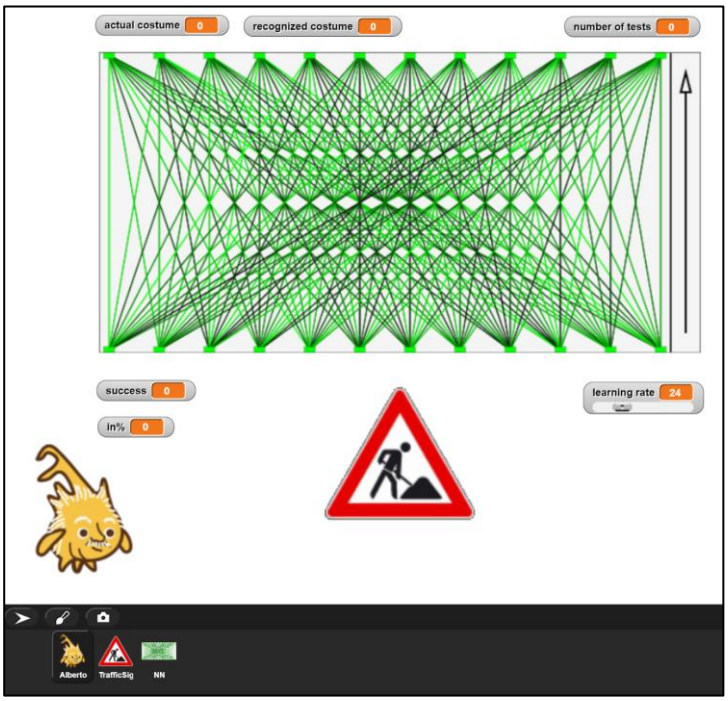

Um die Datenmenge in erträgliche Grenzen zu bringen, verkleinern wir die Pixel auf ein 2x2-Format durch *mean-pooling*, d. h. wir bilden jeweils die Mittelwerte der Farbpixel in den vier Quadranten des Bildes. Aus den 30000 Werten des Verkehrszeichenbildes werden so 12.

Weil es sich um ein schwieriges Problem handelt, übernimmt diesmal *Alberto* die Gesamtsteuerung.

Zum Start verpasst *Alberto* dem NN-Sprite ein neues Kostüm. Danach erzeugt er im NN die Gewichte für ein neues (hier: 12x2) Netz. Dieses lässt er mit einer (noch unsinnigen) Eingabe zeichnen. Danach schickt er das NN an einen gut gewählten Platz in der oberen Mitte und macht dasselbe mit dem Verkehrszeichen darunter. Zuletzt werden einige Variable auf 0 gesetzt. Die brauchen wir später.

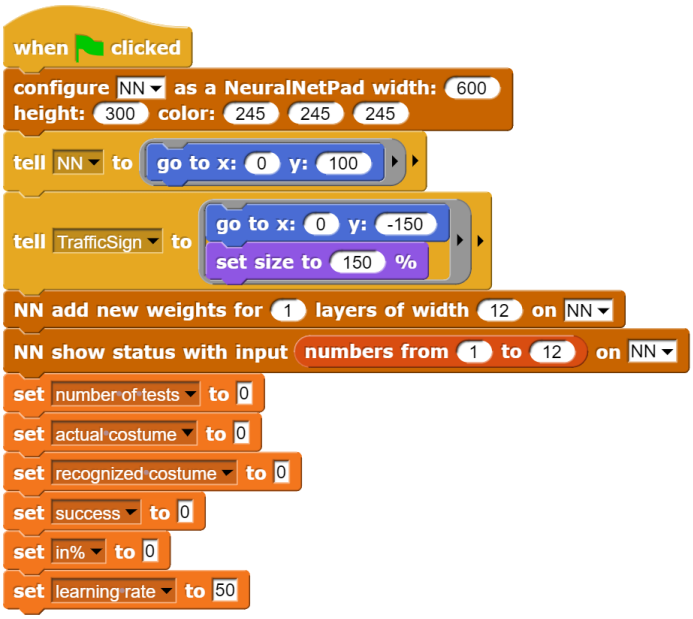

Alberto setzt muss zuerst einmal mithilfe der *Pooling*-Operation die Menge der Bildwerte reduzieren. Um die Operation anwenden zu können, muss er die Bilddaten importieren. Danach kann es sie umrechnen, die vorne in der Liste angegebenen Dimensionen des verkleinerten Bildes löschen und das Ergebnis zurückgeben. Wir fassen alles in einem neuen Block *pooling of <costume>* zusammen.

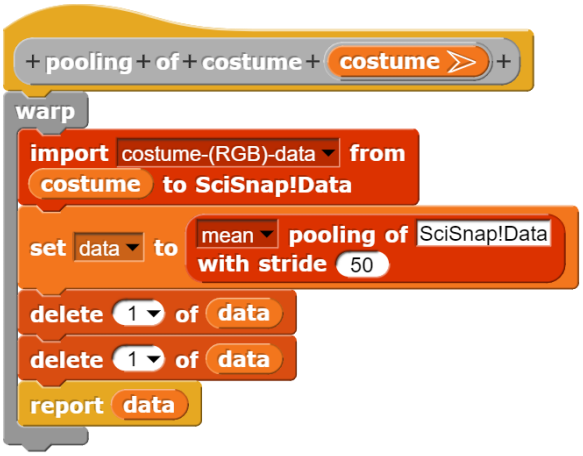

Die Farbwerte des reduzierten Bildes werden von *Alberto* zu einem Eingabevektor zusammengesetzt. Diese werden abschließend mit der *Softmax*-Funktion der *DataLibrary* modelliert, um ungünstige Eingangswerte auszuschließen.

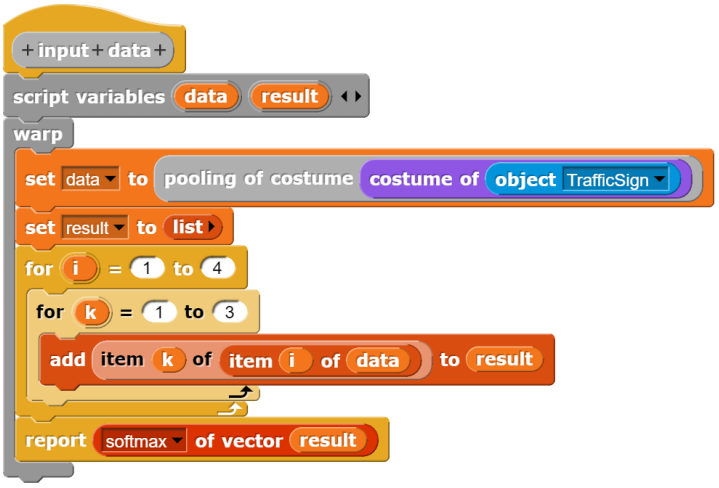

Entsprechend lässt sich der Trainingsvektor in *training data* mit den gesuchten Ausgabewerten des NN ermitteln. In unserem Fall sollen alle Werte 0 sein bis auf den, der der Kostümnummer des Verkehrszeichens entspricht.

Das NN erhält zwei neue Methoden *learn from…* und *test with…* Beim Lernen wird die Position des Platzes mit dem größten Ausgabewert des NN ermittelt und mit der aktuellen Kostümnummer des Verkehrszeichens verglichen. Stimmen diese Werte nicht überein, dann wird weiter gelernt.

Zum Testen wird dieselbe Operation nur einmal ausgeführt.

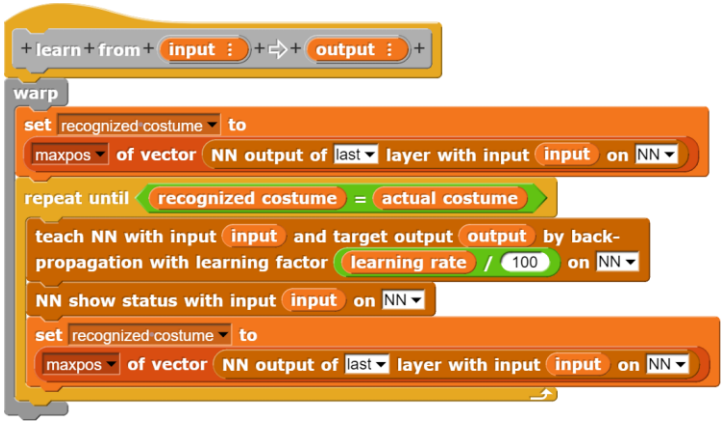

Jetzt haben wir alles zusammen, um *Alberto* vernünftig arbeiten zu lassen.

Ein Lehrvorgang besteht aus der Ermittlung einer zufälligen Kostümnummer mit dem entsprechenden Kostümwechsel. Danach wird der Lernvorgang des NN mit neuen Eingabe- und Zieldaten gestartet. Die Durchgänge werden mitgezählt.

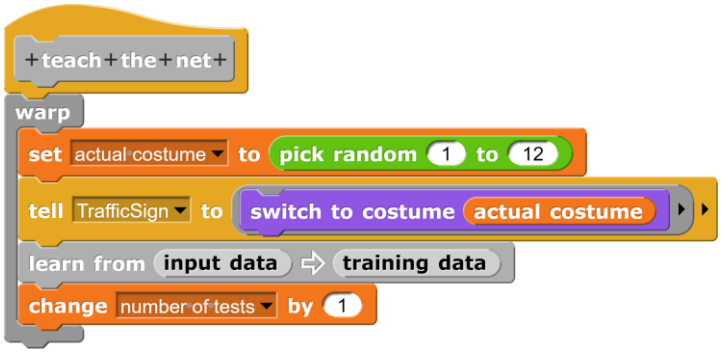

Zum Testen wird ähnlich vorgegangen: Das Kostüm wird gewechselt und geprüft, ob das NN die richtige Kostümnummer berechnet. Ist das der Fall, dann freuen sich alle. Der Prozentsatz der richtigen Versuche wird danach ermittelt.

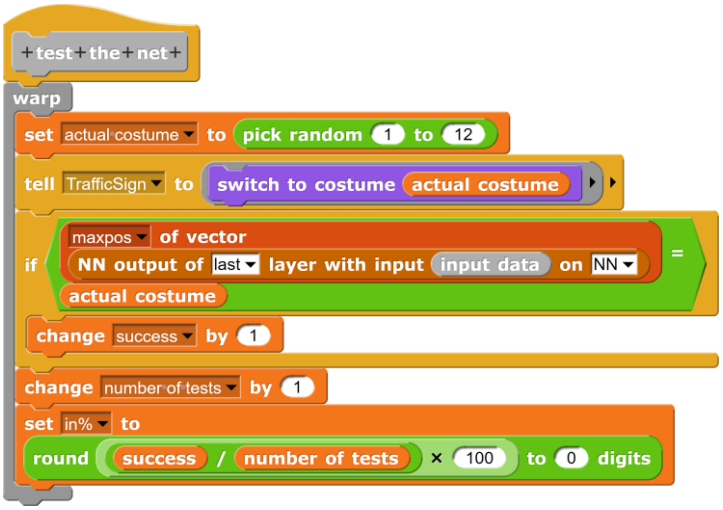

Mehrere Lern- und Testläufe lassen sich dann leicht auslösen.

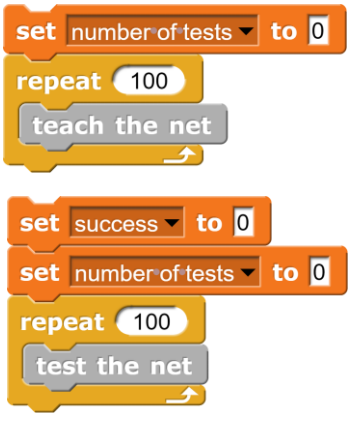

Nach ca. 100 Trainingsläufen mit einer höheren Lernrate und nochmal 100 mit einer geringen zur Feinabstimmung erreichen wir Erkennungsraten von 100%.

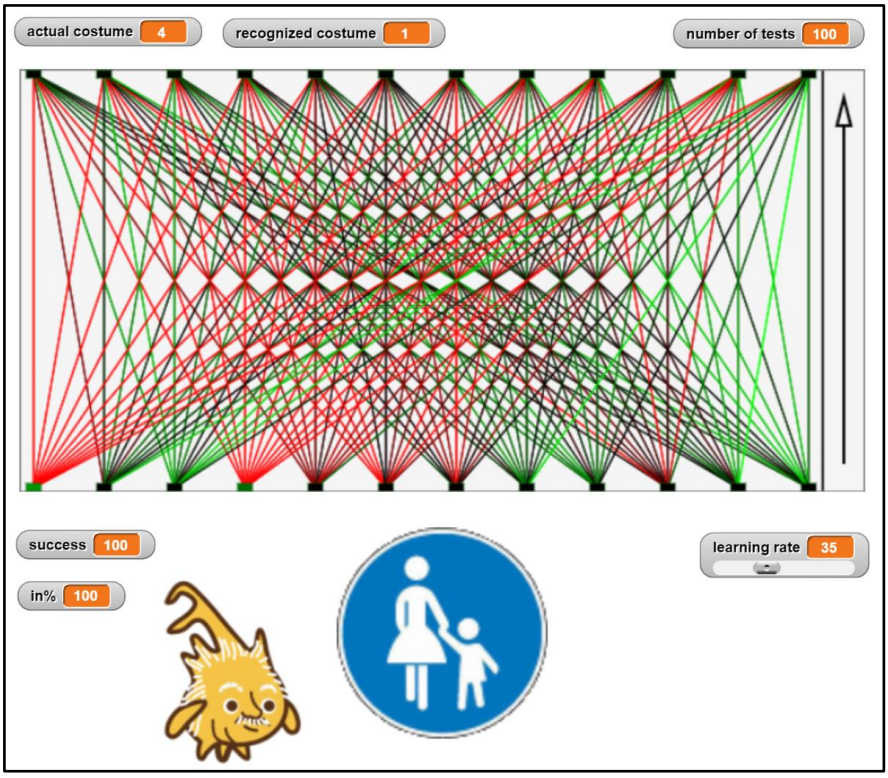

Aufgaben:

1. Trainieren Sie ein einschichtiges Netz mit unterschiedlichen Lernraten und Zahlen der Lerndurchläufe. Ermitteln Sie jeweils prozentual die Erkennungsrate.
2. Stellen Sie die Ergebnisse aus 1. grafisch mithilfe eines *PlotPads* dar.
3. Experimentieren Sie mit mehrschichtigen NNs. Werden die Ergebnisse besser?
4. Vergrößern Sie die Länge des Eingabevektors durch verändertes Pooling. Werden die Ergebnisse besser?
5. Vergrößern Sie die Anzahl der erkennbaren Schilder, indem Sie mehr als eine 1 in der Ausgabe zulassen.

5.50 Zeichenerkennung mit einem Convolutional Neural Network

Die immense Zahl von Parametern in vollständig verbundenen Perzeptron-Netzen und der daraus folgende Bedarf an riesigen Mengen von Trainingsdaten hat zu anderen Netz-Varianten geführt, um diese Zahl drastisch zu reduzieren. Eine davon sind die *Convolutional Neural Networks (CNNs)*, bei denen die Eingabedatenmenge für das Perzeptron-Netz reduziert wird. Diese Art von Netzen wird z. B. in der Bild- und Spracherkennung sehr erfolgreich eingesetzt.

CNNs reduzieren die Datenmenge, indem in einem mehrstufigen Prozess zuerst mehrere Kernels angewandt werden, die bestimmte Eigenschaften z. B. eines Bildes (Kanten, ovale Flächen, …) herausfiltern und so zu mehreren *Feature-Maps* führen, die üblicherweise die gleiche Größe haben wie das Original. Das vergrößert erstmal die Datenmenge. Anschließend wird meist eine nichtlineare Aktivierungs-Funktion (*reLU*) auf die Feature-Maps angewandt und anschließend eine *Pooling*-Operation, die die Datenmenge wieder verkleinert. Meist handelt es sich um *Max-Pooling*, bei dem der Maximalwert aus einem Ausschnitt der Daten bestimmt wird. Macht man das mit einem „Fenster“, das mit einer bestimmten Schrittweite (*stride*) über die Feature-Map bewegt wird, dann erzeugt jeder Pooling-Schritt einen Wert der nächsten, verkleinerten Feature-Map.

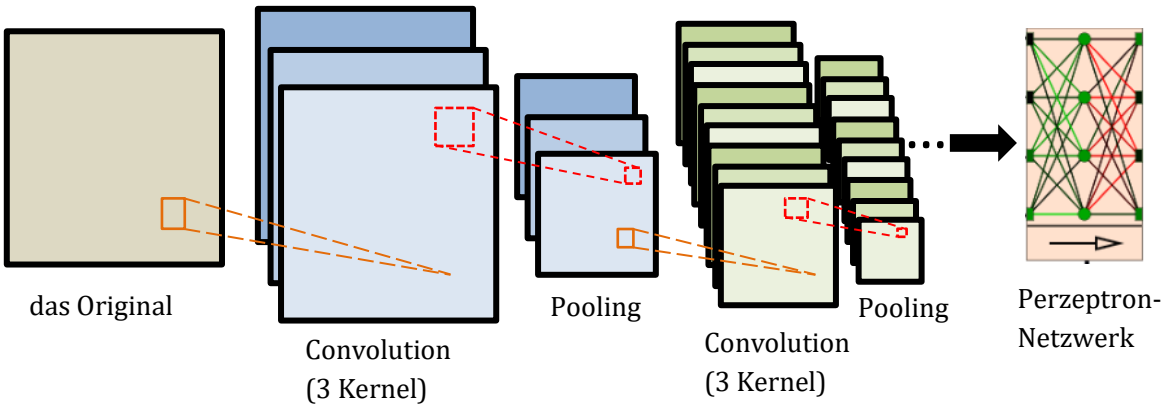

Als Beispiel nehmen wir einen Kernel, der senkrechte Linien filtert: er färbt einen Punkt weiß, wenn sich neben dem Punkt ein zweiter Bildpunkt befindet, sonst schwarz. Im „gefalteten“ Bild können wir dann senkrechte Linien des Originals als helle Flecken erkennen. Kommt es nicht so sehr darauf an, wo genau diese Linien sind, dann verlieren wir nicht allzu viel Information beim Pooling. Ein weißer Punkt in einer Feature-Map nach diversen Pooling-Prozessen bedeutet dann: *„In diesem Bereich befand sich irgendwo eine senkrechte Linie.“* Anhand solcher Daten aus mehreren Feature-Maps kann dann z. B. abgeleitet werden, dass sich dort auch eine horizontale Line, also eine Ecke befand. Hätten wir nach „beigen“ Bereichen sowie „ovalen“ Formen gesucht, dann wäre die Chance, Gesichter zu identifizieren, gar nicht so schlecht.

Wir wollen jetzt ein Modell für so ein CNN bauen, das die handgeschriebenen Ziffern *Null* und *Eins* unterscheiden kann. Dazu benutzen wir ein *DataSprite* für Hilfsoperationen, ein *ImageSprite* für das eigentliche Bild und – natürlich – ein *NeuralNetSprite* für das Perzeptron-Netzwerk am Ende der Kette. Ein weiteres, „normales“ Sprite namens *Control* soll die Abläufe steuern. Damit das Modell leichter zu bedienen ist, ergänzen wir es um einige Buttons sowie einen Stift, um die Oberfläche übersichtlich zu gestalten. Im Screenshot befindet sich das zu analysierende Bild oben im Kästchen, das Neuronale Netz zeigt sein Ergebnis unten an. Dazwischen werden von oben nach unten die verschiedenen Zwischenschichten durchlaufen und angezeigt. Als Zugabe enthält das Modell noch die Möglichkeit, eigene Ziffern zu zeichnen.

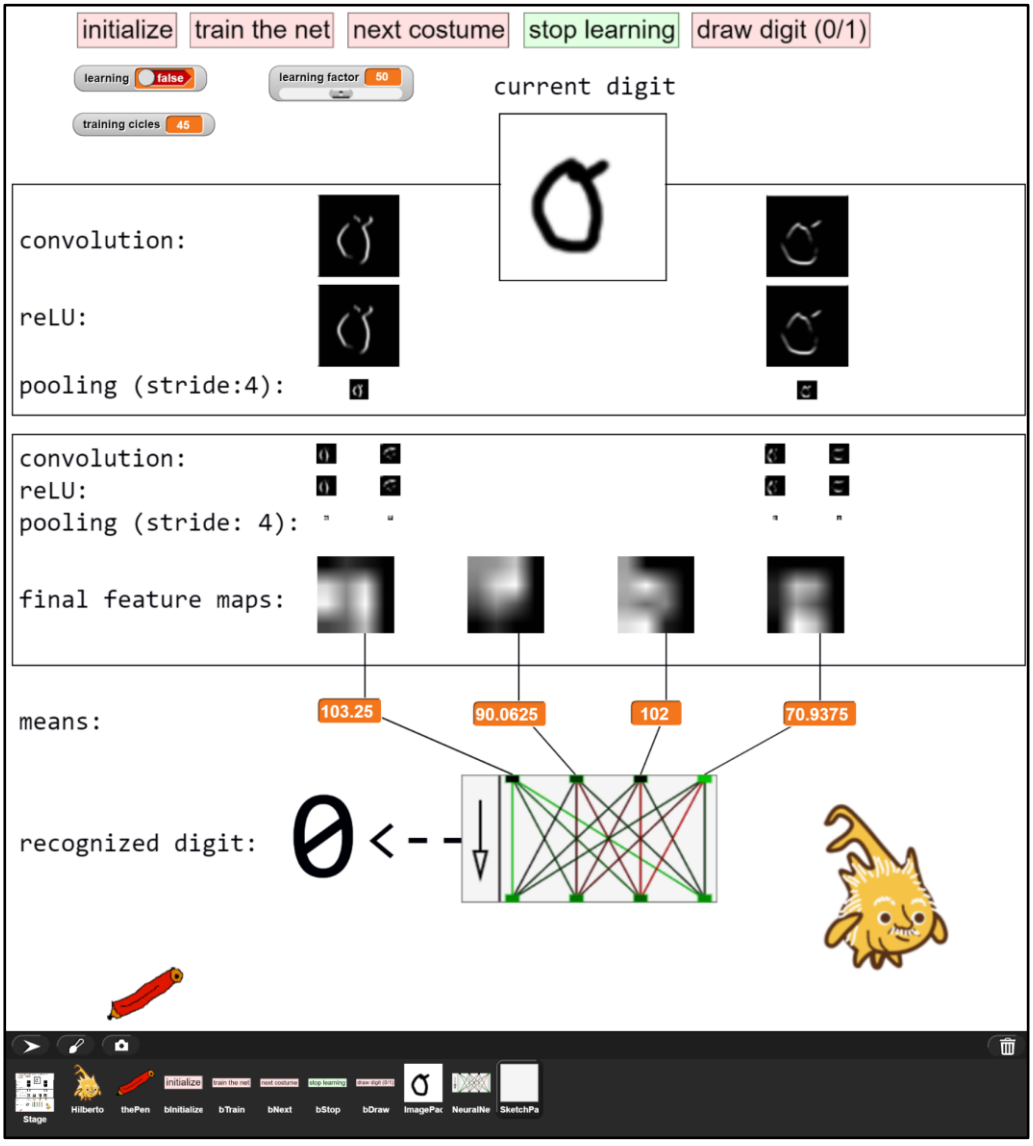

Unser CNN wird mit je 10 Ziffern aus je 64x64 Pixeln für die Nullen und Einsen trainiert. Anschließend soll es diese sowie andere handgeschriebene „erkennen“. Eigentlich müssten wir mehrere Kernel unseres CNN speziell für diese Aufgabe trainieren. Stattdessen nehmen wir nur zwei bekannte Kernel zur Erkennung vertikaler und horizontaler Linien, weil sich durch die Beschränkung auf zwei alles am Bildschirm darstellen lässt und die Ergebnisse sogar halbwegs zu interpretieren sind. (Die Erkennungsrate leidet darunter allerdings heftig!) Trainiert wird also nur das Perzeptron-Netz mit vier Eingangswerten.

Im obigen Bild sind nach zwei Stufen der Reduktion vier Feature-Maps von je 16x16 Pixeln übrig, bei denen jeweils zweimal die Operationen *Convolution* → *reLU* → *Max-Pooling* durchlaufen wurden: ganz links mit dem Kernel für senkrechte Linien, dann mit beiden Kernels in unterschiedlicher Reihenfolge und zuletzt zweimal mit dem Kernel für horizontale Linien. Die Ziffern darunter geben den Mittelwert der Helligkeit gemessen über das gesamte Bild an. Wenden wir dieses auf verschiedene Ziffern an, dann zeigt sich die Möglichkeit, trotz des sehr ein fachen Verfahrens Unterschiede zwischen Nullen und Einsen zu messen.

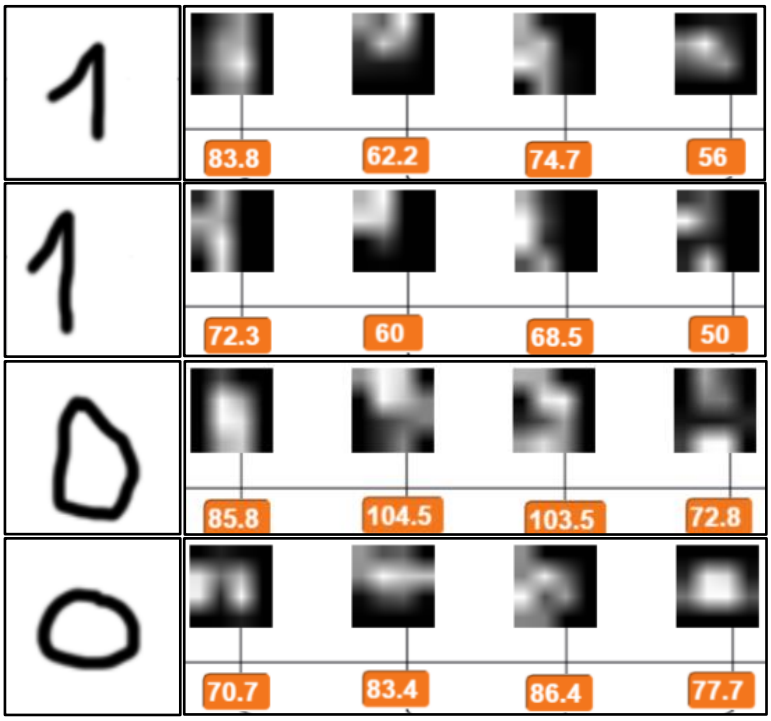

Betrachten wir die Funktionalitäten der einzelnen Objekte:

Das *ImagePad* stellt die Daten eines neuen Kostüms als Grundlage für die Analyse bereit. Dazu erzeugt es eine „erste Schicht“ als Liste *first layer*, die aus zwei Kopien seiner selbst besteht. Auf diesen lässt es dann jeweils eine Faltung (*Convolution*) mit zwei verschiedene anwenden. Danach werden ein paar Linien gezeichnet.

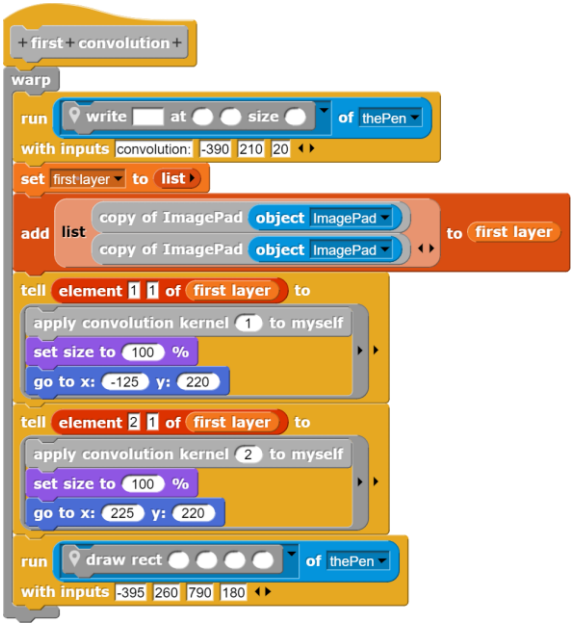

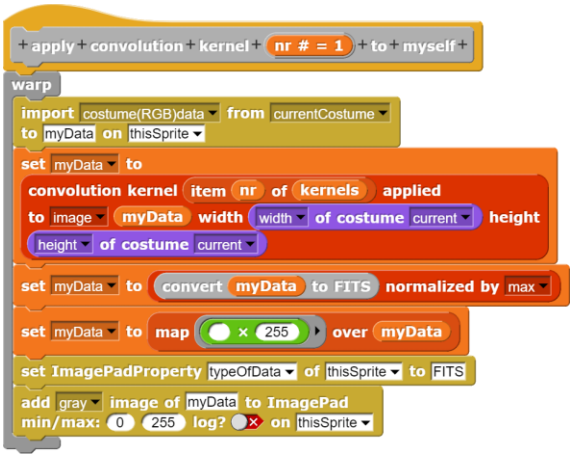

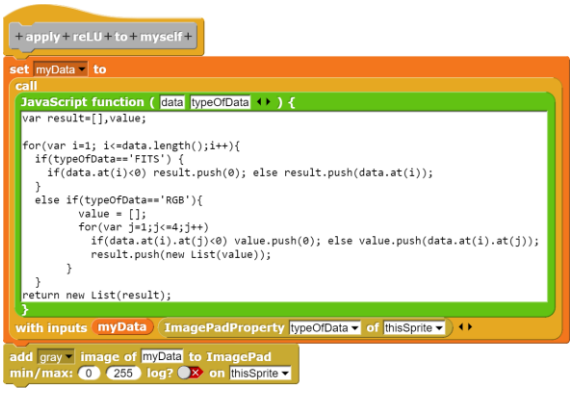

Danach muss jede Kopie eine *reLU* (*rectified linear unit*) durchlaufen, die als Aktivierungsfunktion dient. In diesem Fall werden einfach negative Werte auf Null gesetzt.

Zum Schluss wird jeweils eine Pooling-Operation zur Reduktion der Datenmenge ausgeführt. Als Beispiel ist der Pooling-Vorgang mit den vier Sprites der zweiten Ebene angegeben.

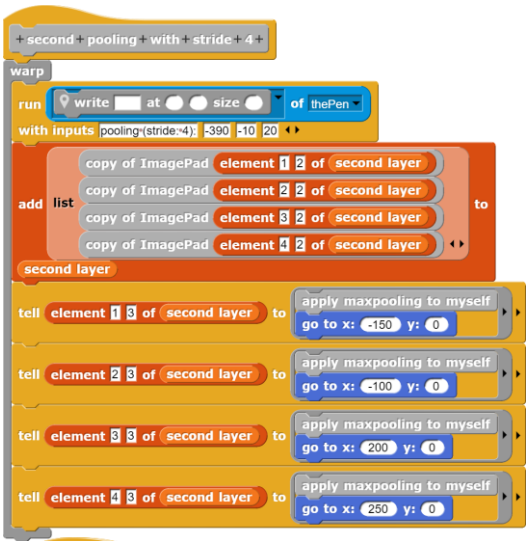

Alberto als Kontrolleur des Ganzen muss das *ImagePad* bitten, das Kostüm zu wechseln und dieses danach zu analysieren. Dabei hält er sich streng an die Vorgaben für CNNs.

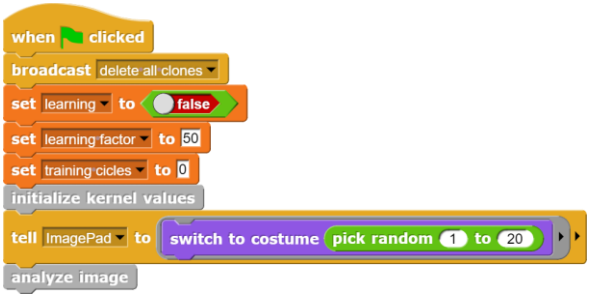

Die Methode *initialize* sorgt nur für das Zeichnen der Linien auf der Bühne. Die weiteren Methoden arbeiten mit zwei Ebenen des CNN, *first layer* und *second layer*, die jeweils die auf der Bühne erscheinenden Versionen der Ziffern enthalten. Damit sich die nicht gegenseitig stören, wird mit Kopien des *ImagePad* gearbeitet, nicht mit Klonen.

Nachdem die erforderlichen Kopien erzeugt wurden, werden diese von *Alberto* gebeten, die jeweilige CNN-Operation auszuführen. Zuletzt werden die inzwischen ziemlich mickrigen (4x4 Pixel) Klone der letzten Ebene als *„final feature maps“* stark vergrößert dargestellt. Mit diesen wird dann das Neuronale Netz trainiert.

Das Neuronale Netz in Form eines *NeuralNetPads* soll bei Nullen die größte Ausgabe am Ausgang 1, bei Einsen am Ausgang 4 erzeugen. Das ist natürlich völlig willkürlich. Den aktuellen Ausgabewert ermittelt die Funktion *output with <input>*. Mit dessen Komponenten kann das Netz trainiert werden, wenn es uns gelingt, aus der letzten Ebene von *second layer* die Mittelwerte zu bestimmen. Diese modellieren wir noch passend mit der *softmax*-Funktion.

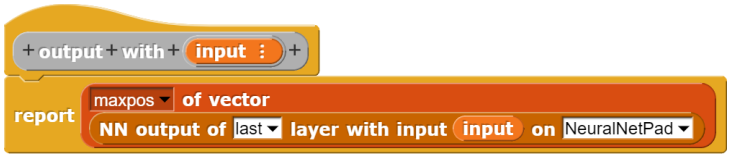

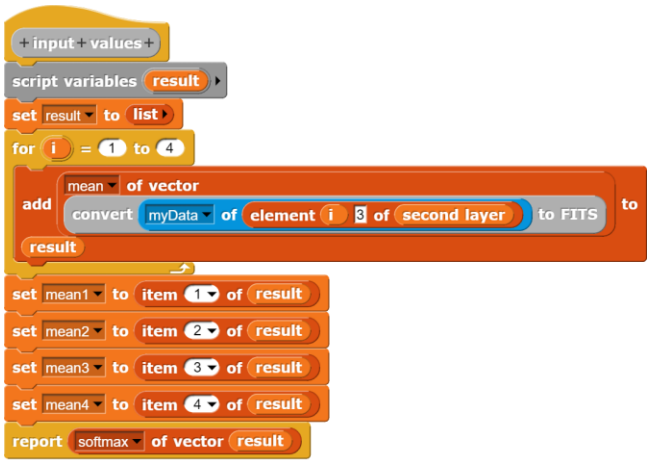

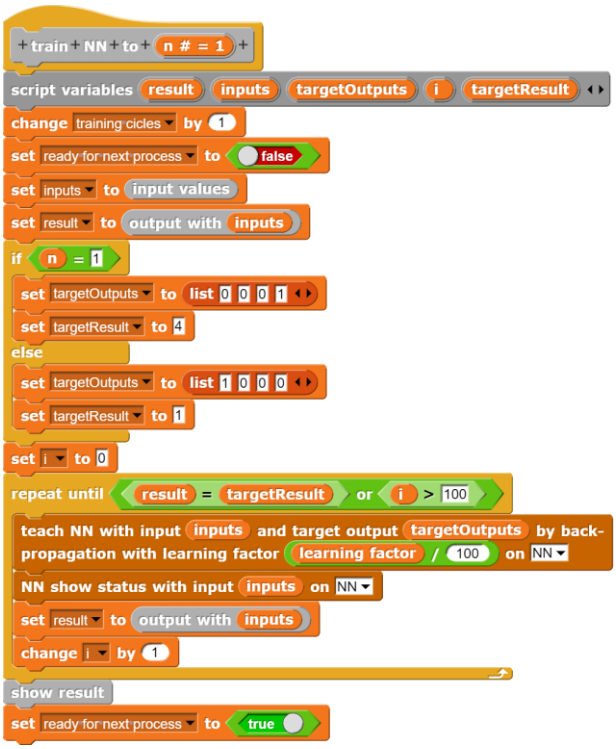

Und – hat das Netz was gelernt? Wir schreiben mal eine Ziffer:

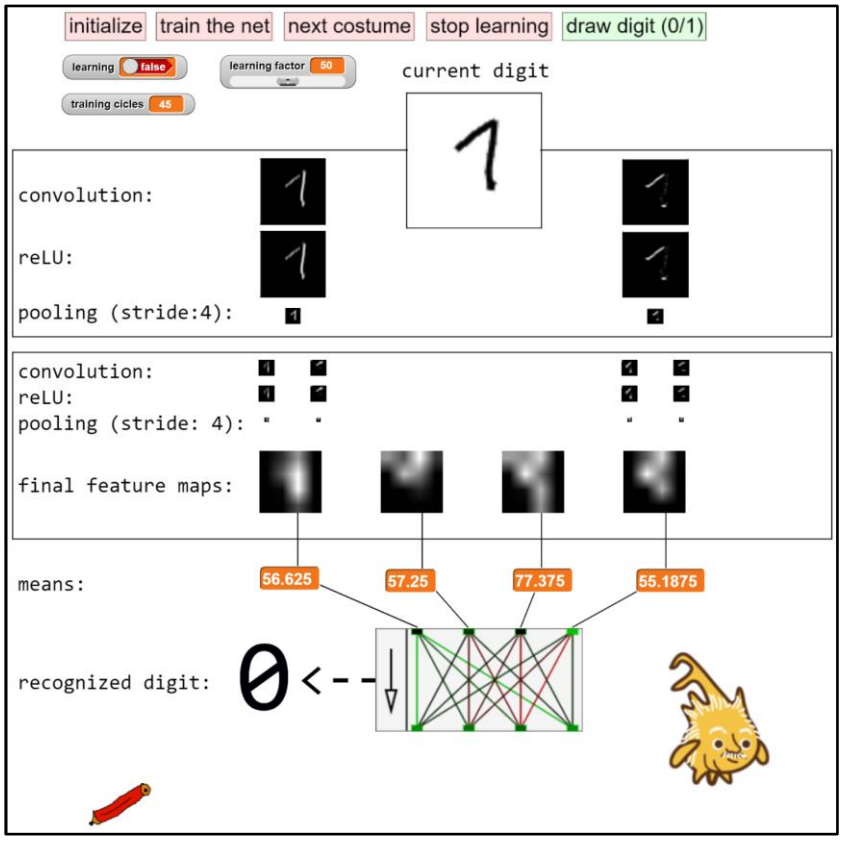

Nun ja – es gibt noch Verbesserungsmöglichkeiten!

Aufgaben:

1. Generieren Sie aus den *final feature maps* eine Liste von 16 Werten.
2. Analysieren Sie diese Liste durch ein Neuronales Netz der Breite 16.
3. Testen Sie, ob die Erkennungsrate insbesondere von neu geschriebenen Ziffern steigt. Falls ja: wie begründen Sie den Effekt?
4. Experimentieren Sie auch mit mehrschichtigen Neuronalen Netzen.

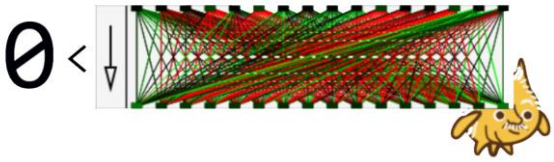

5.51 k-means-Clustering

In der *data*-Palette stehen zwar zwei Blöcke zum *k-means*-Clustering zur Verfügung, aber sie liefern (natürlich) nur das Endergebnis. Wir wollen hier einmal den gesamten Prozess verdeutlichen. Dazu erzeugen wir eine Menge von z. B. 100 Zufallspunkten mit „JavaScript-Koordinaten“, an die wir jeweils noch die Clusternummer anhängen. Die ist anfangs noch „-1“, weil bisher kein Clustering stattgefunden hat. Dazu erzeugen wir „k“, z. B. 5, „Zentren“. Punkte und Zentren stellen wir als Kreise bzw. Quadrate auf der Bühne dar. Die Farben, anfangs grau, bestimmen wir aus der Clusternummer.

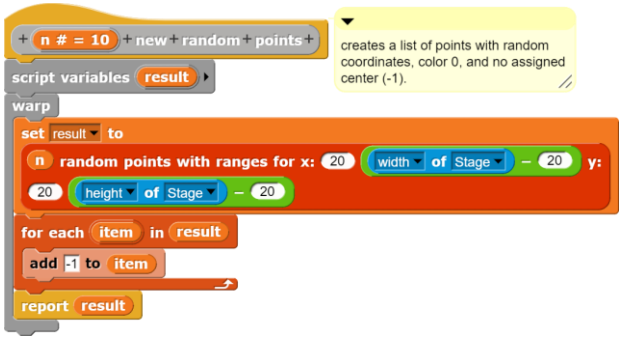

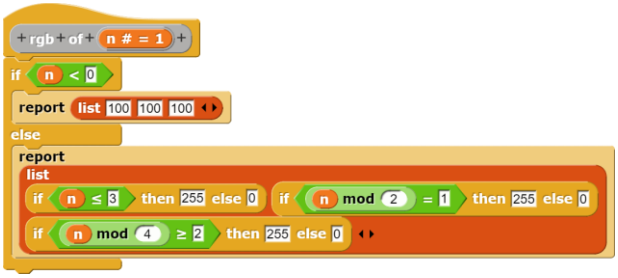

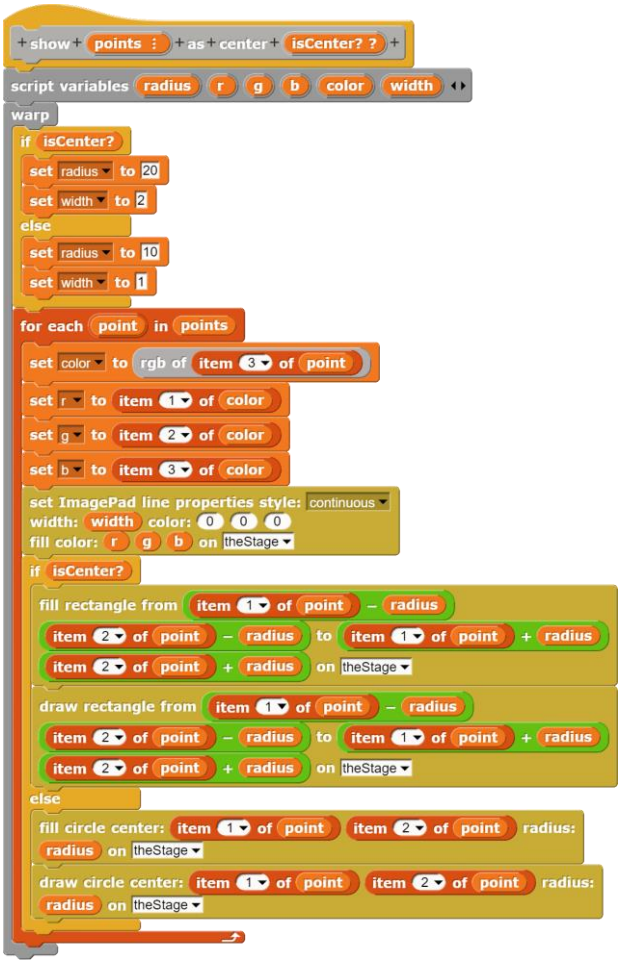

Wir nummerieren die Zentren und tragen ihre Koordinaten in eine Liste *centerPaths* ein, damit wir ihre Bewegungen nachvollziehen können …

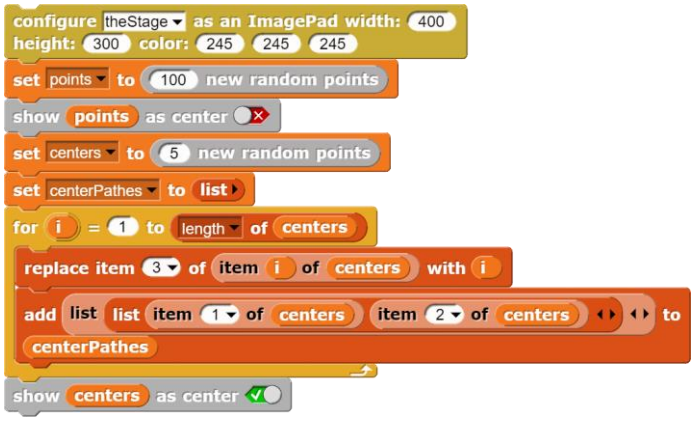

… und erhalten das folgende Bild:

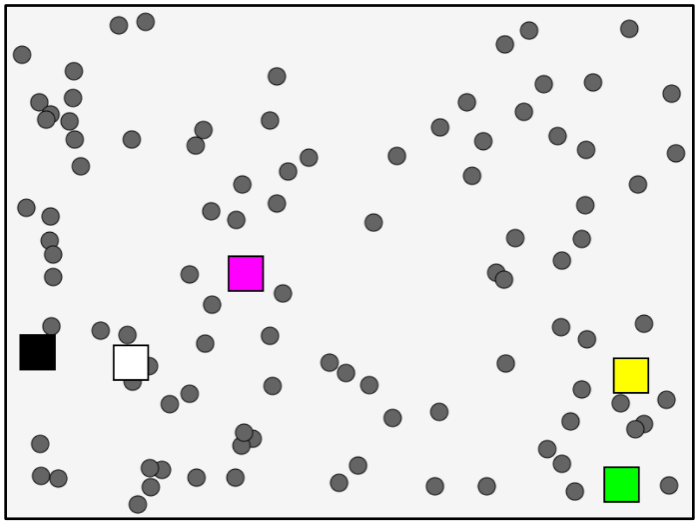

Das k-means-Verfahren bestimmt nun für jeden Punkt das nächstgelegene Zentrum und färbt die Punkte in dessen Farbe ein.

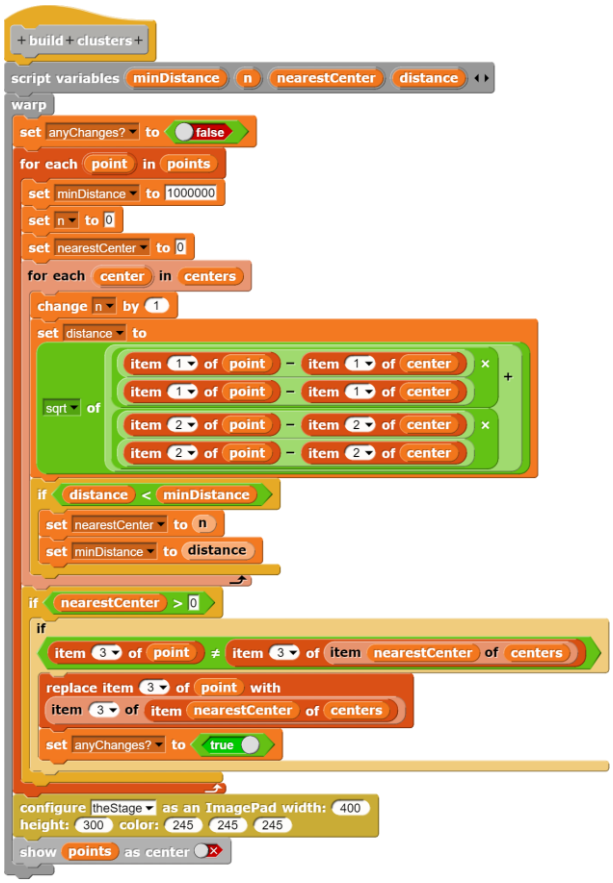

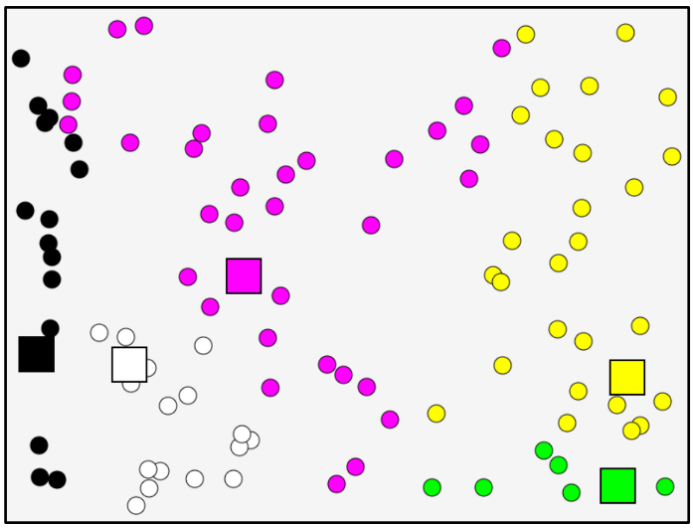

Danach werden die Zentren in den Mittelpunkt der ihnen zugeordneten Punktmenge verschoben. Die neuen Positionen werden in die Positionsliste eingetragen.

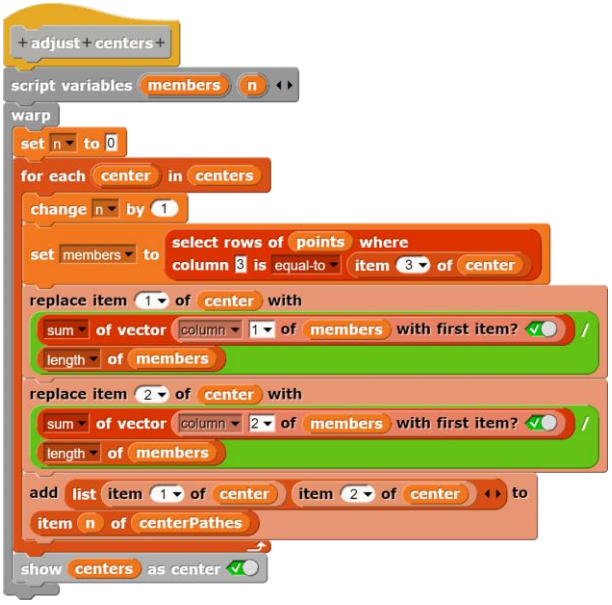

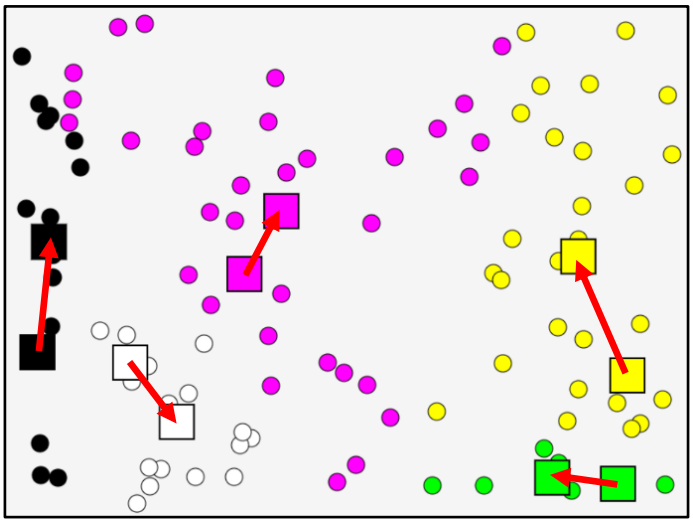

Das Verfahren wird so lange fortgesetzt, bis sich keine Änderungen mehr in den Clustern ergeben. Die Bewegungen der Zentren stellen wir mithilfe der gespeicherten Positionen dar.

Wir erhalten das Ergebnis:

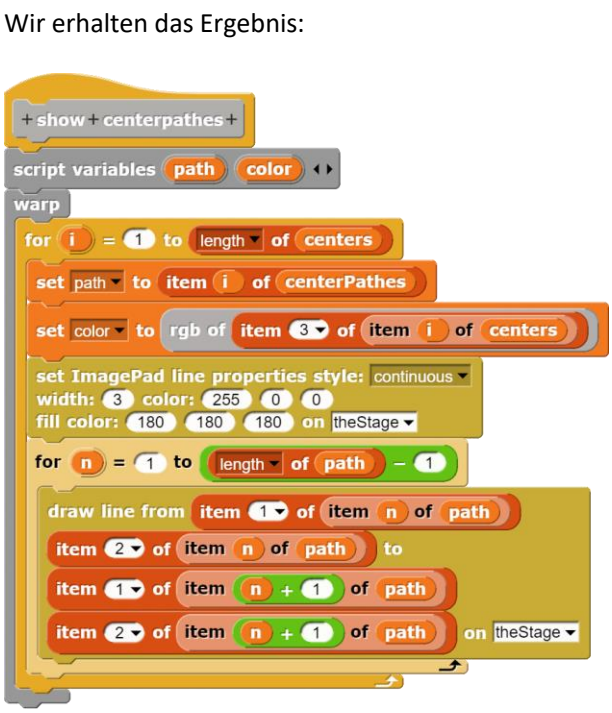

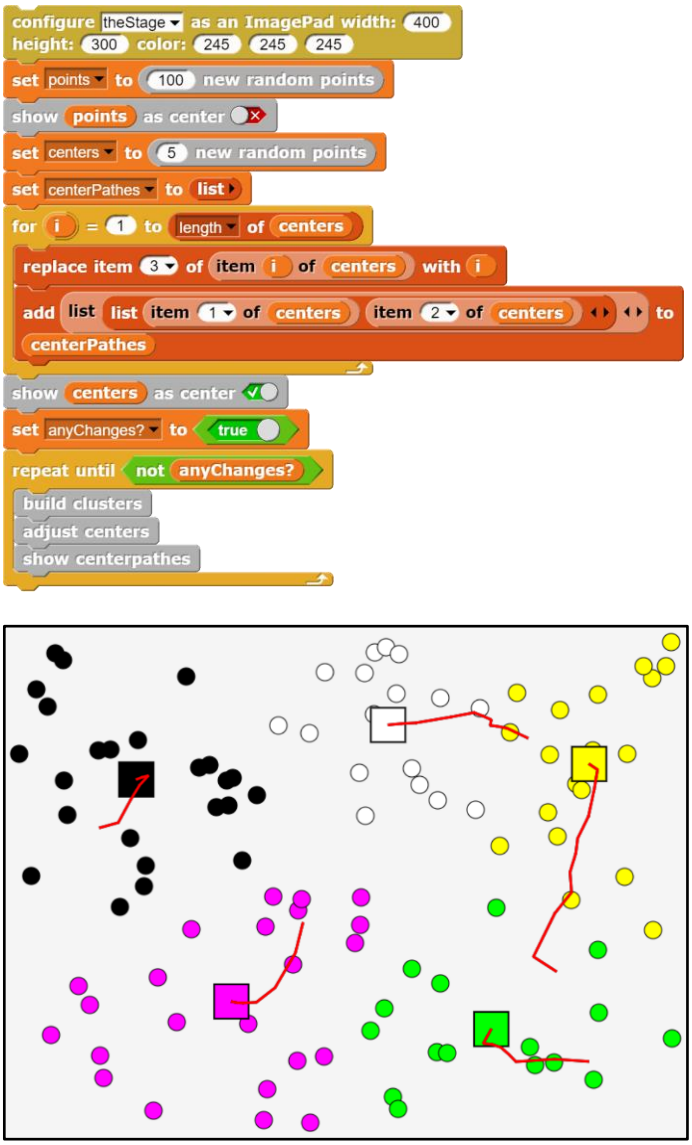

Unter Verwendung der vorhandenen Blöcke hätten wir das Ergebnis natürlich auch etwas einfacher erhalten können – aber eben ohne Darstellung des Prozesses:

5.52 DNA-Verwandtschaften und Levenshtein-Distanz

Wir wollen aus einer Liste von DNA-Sequenzen den nächsten „Verwandten“ zu einer gegebenen DNA-Sequenz bestimmen, z. B. um festzustellen, ob ein Tier von einem Wolf getötet wurde. Dazu erzeugen wir zuerst einmal eine DNA-Liste.

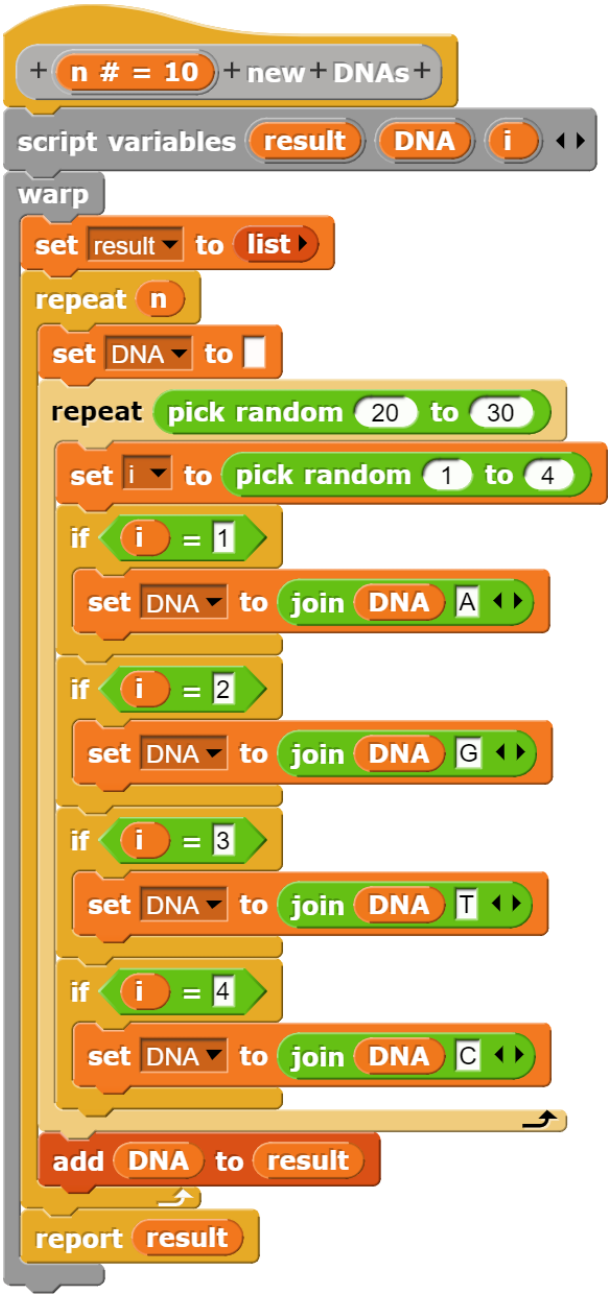

Mithilfe der Levenshtein-Distanz zwischen zwei Zeichenketten können wir nun bestimmen, welche der Zeichenkette der gegebenen am nächsten kommt und wie groß deren Abstand ist.

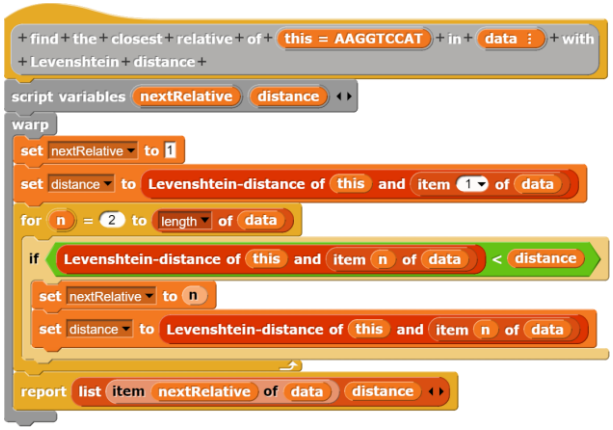

Hinweise

1. *SciSnap!* ist nicht gerade für kleine Displays gedacht, aber auf einem größeren Monitor läuft es prima. 😉
2. Die Beispiele in diesem Skript sollen vor allem unterschiedliche Einsatzmöglichkeiten der *SciSnap!*-Bibliotheken zeigen. Es ist nicht ihre Aufgabe, Beispiele für guten Unterricht oder gute Lehre zu geben, aber sie geben hoffentlich Hinweise, auf welcher Ebene gearbeitet werden kann.
3. Dementsprechend fehlen in diesem Skript weitgehend Beispiele, anhand derer die Lernenden eigene Problemfelder und Lösungen finden und bearbeiten können. Sollten Sie da „best-practice“-Beispiele haben, dann wäre ich auf Hinweise darauf dankbar. Vielleicht könnte eine Sammlung daraus entstehen.
4. Die Bibliotheken enthalten sicherlich noch Fehler und Verbesserungsmöglichkeiten. Für Hinweise darauf wäre ich ebenfalls dankbar.

Ansonsten: Legen Sie los!

Liste der Beispiele

In den meisten Beispielen werden Blöcke mehrerer Bibliotheken zusammen verwendet!

Literaturhinweise und Quellen

[ABELSON] Abelson, Sussman, Sussman: Structure and Interpretation of Computer Programs, MIT Press

[Census] https://archive.ics.uci.edu/ml/datasets/census+income

[DBV] Burger, W., Burge, M.-J-: Digitale Bildverarbeitung – Eine Einführung mit Java und ImageJ, Springer 2006

[FITS] de.wikipedia.org/wiki/Flexible_Image_Transport_System

[HOU] Hands-On Universe: handsonuniverse.org/

[HR] https://studylibde.com/doc/2985884/hertzsprung-russell--und-farb-helligkeits

[JSON] Popular Baby Names: https://catalog.data.gov/dataset/most-popular-baby-names-by-sex-and-mothers-ethnic-group-new-york-city-8c742

[NYcitibike] https://www.citibikenyc.com/system-data

[SchulAstro] www.schul-astronomie.de

[SQL] Modrow, Eckart: Informatik mit Snap!, http://ddi-mod.uni-goettingen.de/InformatikMitSnap.pdf

[UniGOE] Institut für Astrophysik, Universität Goettingen