



Neuronale Netze

Handgeschriebene Ziffern erkennen
im MNIST-Dataset
mit Python und PyTorch



UNIVERSITÄT
DES
SAARLANDES

SIC

Saarland Informatics
Campus



Bild: Pixabay

Künstliche Intelligenz

Definition von Künstlicher Intelligenz:

„Der Begriff **Künstliche Intelligenz** bezeichnet das Verhalten einer Maschine, das – wenn sich ein Mensch genauso verhält – als intelligent angesehen wird.“

Simmons & Cappell, 1988

Definition von Maschinellem Lernen:

„**Maschinelles Lernen** bezeichnet – sehr allgemein formuliert – die Idee, Computern durch geeignete Algorithmen die Fähigkeit zu verleihen, aus Daten und Erfahrungen zu lernen.“

Computer können damit ein **Modell ihrer Welt aufbauen** und die ihnen zugedachten Aufgaben besser lösen.“

Sim BaFin-Studie KI, 2018

Schwache und starke KI

Künstliche Intelligenz lässt sich in zwei Kategorien einteilen.

- **Schwache künstliche Intelligenz:** Sie ist nur auf einen bestimmten Bereich wie Bilderkennung spezialisiert. Innerhalb dieses Bereichs kann sie zwar lernen und eigenständig Probleme lösen. Jedoch kann sie die Lösungen auf andere Bereiche **nicht übertragen**.
- **Starke künstliche Intelligenz:** Sie kann, wie der Mensch, Probleme jeder Art lösen und ist nicht auf einen Bereich spezialisiert. Starke KI ist bisher jedoch **nicht möglich** und nur Science Fiction.

Das machen wir heute

Randnotiz:
ChatGPT ist keine starke KI, auch wenn es über alles reden kann.

ChatGPT ist ein **Large Language Model (LLM)**, das auf Neuronalen Netzen basiert.




Maschinelles Lernen

Maschinelles Lernen (Machine Learning)

Machine Learning ist ein wichtiger Bestandteil der **künstlichen Intelligenz**. Dabei kann ein IT-System auf Basis von **Algorithmen** in **Daten** selbstständig **Muster und Gesetzmäßigkeiten** erkennen. So kann maschinelles Lernen mithilfe von **Daten** **Vorhersagen** treffen. Außerdem kann es durch Erfahrungen lernen, eigenständig **neue Probleme** zu lösen.


Anwendungsbeispiele für Machine Learning findest du viele:

- **Personalisierung im Marketing:** Machine Learning erkennt die Vorlieben und das Kaufverhalten von Kunden und kann so passende Produktempfehlungen liefern.
- **Autonomes Fahren:** Das Fahrzeug nimmt verschiedene Sensordaten aus dem Straßenverkehr auf und lernt, darauf passend zu reagieren.
- **IT-Security:** Machine Learning Modelle können mithilfe umfangreicher Datenanalysen schon früh Unregelmäßigkeiten erkennen. So wird betrügerisches Verhalten (z. B. bei Kreditkartenbetrug) schnell unterbunden.



Paradigmen des maschinellen Lernens - Verstärkendes Lernen

Verstärkendes Lernen




Paradigmen des maschinellen Lernens - Unüberwachtes Lernen

Unüberwachtes Lernen


Unbeschriftete Eingaben
erhalten



Ähnlichkeiten in den
Eingaben erkennen
und Muster finden




In der Eingabe
Gruppen und Ausreißer
identifizieren




Paradigmen des maschinellen Lernens - Überwachtes Lernen

Überwachtes Lernen


Beschriftete Eingaben
erhalten



Regeln finden, die
bekannte Eingaben
richtig beschriften



Neue Eingaben
entsprechend der gefundenen
Regeln beschriften




Trainings- und Testdaten




Datensatz


Trainings- und Testdaten




Trainings- und Testdaten



Trainings- und Testdaten



Trainings- und Testdaten



Aufgabe heute:

Ein künstliches Neuronales Netz

zum überwachten Lernen implementieren

Gegeben / Kundenwunsch

- Daten für überwachtes Lernen (MNIST)
- Künstliches Neuronales Netz (KNN)
- Python
- PyTorch
- Jupyter Notebook
- Google Colab oder Visual Studio Code


Gesucht / Euer Job

- Layout des KNN: Anzahl Neuronen (Input, Output, Hidden), Anzahl Layer
- Funktionen bei Benutzung des KNN, z.B. Aktivierungsfunktion
- Funktion für Verbesserung des KNN, z.B. Minimierung einer Verlustfunktion
- Anzahl Trainingszyklen, Viel hilft viel?
- Bewertung der Güte des KNN, z.B. Accuracy




(Künstliche) Neuronale Netze


Neuronales Netz - Aufbau




Aktivierung eines Neurons im Neuronalen Netz




Aktivierung eines Neurons im Neuronalen Netz




Aktivierung eines Neurons im Neuronalen Netz




Aktivierung eines Neurons im Neuronalen Netz




Aktivierung eines Neurons im Neuronalen Netz




Aktivierung eines Neurons im Neuronalen Netz





Aktivierung eines Neurons im Neuronalen Netz





Aktivierung eines Neurons im Neuronalen Netz




Aktivierung eines Neurons im Neuronalen Netz



Aktivierung eines Neurons im Neuronalen Netz



(Forward) Propagation



Genauigkeit des Neuronalen Netzes (Accuracy)

$$\text{Accuracy} = \frac{\text{Number of correct predictions}}{\text{Total number of predictions}}$$

<https://developers.google.com/machine-learning/crash-course/classification/accuracy?hl=de>

Es gibt weitere Metriken, um Modelle des maschinellen Lernens zu bewerten:

- Precision
- Recall / Sensitivität
- F1-Score
- Spezifität

Diese Metriken betrachten wir heute nicht.


<https://artemoppermann.com/de/accuracy-precision-recall-f1-score-und-specificity/>

Um die **Accuracy** zu berechnen, werden **gelabelte Daten** benötigt, mit denen das Netz **nicht trainiert** worden ist.
-> Testdaten

Training des KNN: Back Propagation

Bild der Ziffer

8



8


Größte Aktivierung

Richtig!

Gewichte verstärken!

Bild der Ziffer

8



3

Größte Aktivierung

Falsch!

Gewichte verringern!

Training = Gewichte ändern

Verlustfunktion (Loss)

Für Klassifikationsaufgaben, bei denen das neuronale Netz Wahrscheinlichkeitswerte im Intervall (0, 1) berechnen soll, wird die sog. Kreuzentropie verwendet (engl: **Cross-Entropy**).

Die Kreuzentropie für eine berechnete Wahrscheinlichkeitsverteilung $\vec{y}^{(n)}$ und die tatsächliche Wahrscheinlichkeitsverteilung $\vec{t}^{(n)}$ ist definiert gemäß:

$$E_{cross} = - \sum_{m=1}^M t_m \cdot \log(y_m)$$

Aber heute: Kein Mathe,
Ziel **Implementierung**.

<https://artemoppermann.com/de/training-der-kuenstlichen-neuronalen-netze/>

Der “Loss” ist **keine Prozentangabe**, die angibt, wie gut das Netz allgemein arbeitet.
Er ist ein **Gütekriterium**, dass die Entscheidung des KNN bewertet.

Erinnerung: Um die Korrektheit des KNN anzugeben, berechnet man die **Accuracy**.

Ausflug: Gradient Descent visualisiert (für Back Propagation)








Bild: Wikipedia

MNIST Dataset

Das MNIST Dataset


Die **MNIST-Datenbank** (*Modified National Institute of Standards and Technology database*^[1]) ist eine öffentlich verfügbare **Datenbank** von handgeschriebenen Ziffern. Wobei jede Ziffer als **28 × 28 Pixel** großes Graustufen-Bild gespeichert ist^[1]. Die MNIST-Datenbank besteht aus **60.000 Beispielen im Trainingsdatensatz** und **10.000 Beispielen im Testdatensatz**.

<https://de.wikipedia.org/wiki/MNIST-Datenbank>




Ein Eintrag aus dem MNIST-Dataset

Bild




28 x 28 = 784 Pixel

Label



6




Aufgabe: Handgeschriebene Ziffern erkennen


Mit einem Teil der MNIST-Ziffern ein Neuronales Netz trainieren (**Trainingsdaten**).

Danach mit einem anderen Teil der MNIST-Ziffern bewerten, wie gut das Neuronale Netz arbeitet (**Testdaten**).

Neuronales Netzwerk für die MNIST-Aufgabe - Input Layer




Neuronales Netzwerk für die MNIST-Aufgabe - Output Layer



Input Layer


- 784 Inputs (28×28)
- 'Flatten' layer
- Normalized inputs




Output Layer


- 10 Outputs
- 'Dense' layer
- Softmax function


Neuronales Netzwerk für die MNIST-Aufgabe - Hidden Layer





3Blue1Brown






Implementierung



Jupyter Notebook (in Google Colab)

- Jupyter Notebooks sind eine Laufzeitumgebung für **Python**. Sie laufen in verschiedenen **Entwicklungsumgebungen**, z.B. Visual Studio Code, als auch im **Webbrowser**
- Es können sich **Code- und Textblöcke** abwechseln. Projekte können erklärt werden.
- Codeblöcke können **ausgeführt** werden. Die Ausgabe erscheint unter dem Block.
- Viele KI-Projekte insbesondere zu **Datascience**, wo oft Daten visualisiert werden müssen, nutzen Jupyter Notebooks.
- **Google Colab** ist eine **Online-Umgebung** für Jupyter Notebooks
- Genutzt wird die Rechenleistung der **GoogleServer**. Das eigene Endgerät wird nicht genutzt.
- Colab kann **kostenlos** genutzt werden. Gegen **Aufpreis** kann Serverleistung dazugekauft werden.




Bibliothek PyTorch



PyTorch ist eine auf **Maschinelles Lernen** ausgerichtete **Open-Source-Programmbibliothek** für die **Programmiersprache Python**, basierend auf der in **Lua** geschriebenen Bibliothek **Torch**, die bereits seit 2002 existiert.^{[2][3][4]} Entwickelt wurde PyTorch von dem **Facebook-Forschungsteam** für **künstliche Intelligenz**.^{[5][6][7]} Im September 2022 wurde Pytorch mittels der neugegründeten Pytorch Foundation Teil der **Linux Foundation**.^[8]

<https://de.wikipedia.org/wiki/PyTorch>

Implementierung im Jupyter Notebook (in Google Colab)



```
1 import torch
2 import torch.nn as nn
3
4 # Definiere das neuronale Netzwerk
5 class SimpleNN(nn.Module): # erbt von nn.Module
6     def __init__(self):
7         super(SimpleNN, self).__init__()
8         self.fc1 = nn.Linear(28*28, 128) # fc1 = fully connected layer, 28x28=784 in, 128 out
9         self.relu = nn.ReLU()           # Rectified Linear Unit (gerichtetes lineares Element)
10                                         # f(x) = max(0, x)
11         self.fc2 = nn.Linear(128, 10)    # 128 in, 10 out
12
13     def forward(self, x):
14         x = x.view(-1, 28*28) # Flattening der Eingabe
15         x = self.fc1(x)
16         x = self.relu(x)
17         x = self.fc2(x)
18         return x
```

<https://colab.research.google.com/drive/1siDxH4qgLSR64tf8Qfmn3jM6j16pCHs9?usp=sharing>

Block 1 Definition des Neuronalen Netzes (Klasse definieren)

```

1 # Block 1
2 import torch
3 import torch.nn as nn
4
5 # Definiere das neuronale Netzwerk
6 class SimpleNN(nn.Module): # erbt von nn.Module
7     def __init__(self):
8         super(SimpleNN, self).__init__()
9         self.fc1 = nn.Linear(28*28, 128) # fc1 = fully connected layer, 28x28=784 in, 128 out
10        self.relu = nn.ReLU() # Rectified Linear Unit (gerichtetes lineares Element)
11        # f(x) = max(0, x)
12        self.fc2 = nn.Linear(128, 10) # 128 in, 10 out
13
14    def forward(self, x):
15        x = x.view(-1, 28*28) # Flattening der Eingabe
16        x = self.fc1(x)
17        x = self.relu(x)
18        x = self.fc2(x)
19        return x
20
21 # Model für das Neuronale Netz instantiieren
22 model = SimpleNN()

```

Selber programmieren nach Block 1 - Beispiel



```
1 # Selber programmieren nach Block 1  
2 print(model)
```

```
SimpleNN(  
    (fc1): Linear(in_features=784, out_features=128, bias=True)  
    (relu): ReLU()  
    (fc2): Linear(in_features=128, out_features=10, bias=True)  
)
```

Block 2 Transformationsfunktion definieren

```
1 # Block 2
2 from torchvision import transforms
3
4 # Lade das MNIST-Dataset und wende Transformationen an
5 transform_function = transforms.Compose([transforms.ToTensor(), transforms.Normalize((0.5,), (0.5,))])
```

Selber programmieren nach Block 2 - Beispiel

```
1 # Selber programmieren nach Block 2
2 print(transform_function)
```

```
Compose(
  ToTensor()
  Normalize(mean=(0.5,), std=(0.5,))
)
```

Block 3 Trainings- und Testdaten herunterladen

```
1 # Block 3
2 from torchvision import datasets
3
4 training_data = datasets.MNIST(root='./data', train=True, download=True, transform=transform_function)
5 test_data = datasets.MNIST(root='./data', train=False, download=True, transform=transform_function)
```

➞ Downloading <http://yann.lecun.com/exdb/mnist/train-images-idx3-ubyte.gz>
Downloading <http://yann.lecun.com/exdb/mnist/train-images-idx3-ubyte.gz> to ./data/MNIST/raw/train-images-idx3-ubyte.gz
100%|██████████| 9912422/9912422 [00:00<00:00, 222824510.25it/s]Extracting ./data/MNIST/raw/train-images-idx3-ubyte.gz to ./data/MNIST/raw

Downloading <http://yann.lecun.com/exdb/mnist/train-labels-idx1-ubyte.gz>
Downloading <http://yann.lecun.com/exdb/mnist/train-labels-idx1-ubyte.gz> to ./data/MNIST/raw/train-labels-idx1-ubyte.gz
100%|██████████| 28881/28881 [00:00<00:00, 69180864.55it/s]
Extracting ./data/MNIST/raw/train-labels-idx1-ubyte.gz to ./data/MNIST/raw

Downloading <http://yann.lecun.com/exdb/mnist/t10k-images-idx3-ubyte.gz>
Downloading <http://yann.lecun.com/exdb/mnist/t10k-images-idx3-ubyte.gz> to ./data/MNIST/raw/t10k-images-idx3-ubyte.gz
100%|██████████| 1648877/1648877 [00:00<00:00, 65769796.36it/s]
Extracting ./data/MNIST/raw/t10k-images-idx3-ubyte.gz to ./data/MNIST/raw

Downloading <http://yann.lecun.com/exdb/mnist/t10k-labels-idx1-ubyte.gz>
Downloading <http://yann.lecun.com/exdb/mnist/t10k-labels-idx1-ubyte.gz> to ./data/MNIST/raw/t10k-labels-idx1-ubyte.gz
100%|██████████| 4542/4542 [00:00<00:00, 5729482.34it/s]
Extracting ./data/MNIST/raw/t10k-labels-idx1-ubyte.gz to ./data/MNIST/raw

Selber programmieren nach Block 3 - Beispiel

```
1 # Selber programmieren nach Block 3  
2 print(len(training_data))  
3 print(len(test_data))  
4 print(training_data[0])
```

60000
10000
(tensor([[-1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000,
 -1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000,
 -1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000,
 -1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000],
 [-1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000,
 -1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000,
 -1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000,
 -1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000],
 [-1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000,
 -1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000,
 -1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000,
 -1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000],
 [-1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000,
 -1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000,

Block 4 Trainings- und Testdaten in Datenstruktur laden

```
1 # Block 4
2 from torch.utils.data import DataLoader
3
4 training_loader = DataLoader(dataset=training_data, batch_size=64, shuffle=True)
5 test_loader = DataLoader(dataset=test_data, batch_size=64, shuffle=False)
```

Dataset stores the samples and their corresponding labels, and **DataLoader** wraps an iterable around the Dataset.

https://pytorch.org/tutorials/beginner/basics/quickstart_tutorial.html?highlight=dataloader

Bei Batchsize 64 ergeben sich 938 Batches im Trainingsset.

Selber programmieren nach Block 4 - Beispiel

```
1 # Selber programmieren nach Block 4
2 print(training_loader)
3 print(len(training_loader))
4 print(len(test_loader))
5 print(len(training_loader)*64)
6 print(len(test_loader)*64)
```

```
<torch.utils.data.data_loader.DataLoader object at 0x7df9683db5e0>
938
157
60032
10048
```

Block 5 Neuronales Netz instantiieren, Loss und Optimierer definieren

```
1 # Block 5
2 import torch.optim as optim
3
4 # Verlustfunktion (Loss) und Optimierer definieren
5 loss_function = nn.CrossEntropyLoss()
6 optimization_algorithm = optim.SGD(model.parameters(), lr=0.01) # SGD = stochastic gradient descent,
7                               # lr = learning rate
```

<https://pytorch.org/docs/stable/generated/torch.nn.CrossEntropyLoss.html>

<https://pytorch.org/docs/stable/generated/torch.optim.SGD.html>

SGD Implements stochastic gradient descent

Selber programmieren nach Block 5 - Beispiel

```
1 # Selber programmieren nach Block 5
2 print(loss_function)
3 print(optimization_algorithm)
```

```
CrossEntropyLoss()
SGD (
Parameter Group 0
    dampening: 0
    differentiable: False
    foreach: None
    lr: 0.01
    maximize: False
    momentum: 0
    nesterov: False
    weight_decay: 0
)
```

Block 6 Neuronales Netz trainieren

```

1 # Block 6
2 # Trainingsloop
3 num_epochs = 1
4
5 print("Starte Training")
6 for epoch in range(num_epochs):
7     for batch_index, (images, labels) in enumerate(training_loader):
8         optimization_algorithm.zero_grad()
9         outputs = model(images)      # forward wird aufgerufen, wenn data durch das Model geleitet wird
10        # outputs = bis zu 64 (batch_size) Wahrscheinlichkeitsverteilungen für jeweils all 10 Ziffern
11        # [-4.8741e+00,  6.0430e+00,  1.4008e+00,  1.1718e+00, -2.7590e+00,
12        #  3.0154e-01, -4.9669e-01,  6.0514e-01,  8.4430e-01, -7.3287e-01]
13        loss = loss_function(outputs, labels)
14        loss.backward()
15        optimization_algorithm.step()
16
17        if batch_index % 100 == 0:
18            print(f'Epoch {epoch+1}/{num_epochs}, Batch {batch_index}/{len(training_loader)}, Loss: {loss.item()}')
19 print("Traning fertig!")

```

```

Epoch 1/1, Batch 0/938, Loss: 0.16773580014705658
Epoch 1/1, Batch 100/938, Loss: 0.22459541261196136
Epoch 1/1, Batch 200/938, Loss: 0.2589246332645416
Epoch 1/1, Batch 300/938, Loss: 0.2684001922607422

```

https://inf-schule.de/informatiksysteme/kuenstliche-intelligenz/maschinelles-lernen/maschinelles_lernen

```
1 # Selber programmieren nach Block 6
2 print(len(outputs))
3 print(outputs[0])
4 print(labels[0])
5 print(len(labels))
6 print(images[0])
```



```
32
tensor([ 0.7932, -2.6793,  2.3830, -0.8346,  2.2291, -0.6511,  6.6040, -3.6512,
         0.9268, -2.0978], grad_fn=<SelectBackward0>)
tensor(6)
32
tensor([[[-1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000,
          -1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000,
          -1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000,
          -1.0000],
        [-1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000,
          -1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000,
          -1.0000, -1.0000, -1.0000, -1.0000, -1.0000, -1.0000,
          -1.0000]]])
```


Block 7 Trainiertes Neuronales Netz mit Testdaten evaluieren

```
1 # Block 7
2 # Evaluierung auf dem Testdatensatz
3 model.eval()
4 correct = 0
5 total = 0
6
7 with torch.no_grad():
8     for image, label in test_loader:
9         outputs = model(image)
10        _, predicted = torch.max(outputs.data, 1)
11        total += label.size(0)
12        correct += (predicted == label).sum().item()
13
14 accuracy = correct / total
15 print(f'Genauigkeit auf dem Testdatensatz: {accuracy * 100:.2f}%')
```



Genauigkeit auf dem Testdatensatz: 92.98%

Selber programmieren nach Block 7 - Beispiel

```

1 # Selber programmieren nach Block 7
2 print(correct)
3 print(total)


```


 8936
 10000


8 Zufälliges Bild nehmen und vom NN erkennen lassen

```
1 # Block 8
2 import matplotlib.pyplot as plt
3 import random
4
5 random_index = random.randint(0, len(test_data) - 1)
6 random_image, random_label = test_data[random_index]
7
8 plt.imshow(random_image[0], cmap='gray')
9 plt.show()
10
11 # Vorhersage für das zufällige Bild
12 model.eval()
13 with torch.no_grad():
14     output = model(random_image.view(-1, 28*28))
15     _, predicted = torch.max(output, 1)
16
17 print("\n", f'Das neuronale Netzwerk erkennt: {predicted.item()}, tatsächliches Label: {random_label}')
```


Gewähltes Bild und erkannte Zahl - richtig




Gewähltes Bild und erkannte Zahl - richtig



Gewähltes Bild und erkannte Zahl - falsch



Gewähltes Bild und erkannte Zahl - richtig mit Wahrscheinlichkeit





Abschluss

Bemerkungen


- Das “Netz” ist nur eine Visualisierung einer mathematischen Funktion mit **sehr vielen** Parametern.
- Die Gewichte im Neuronalen Netz haben keine “Bedeutung”. Damit sind die Entscheidungen des Neuronalen Netzes auch **nicht erklärbar**. Das ist ein Nachteil - insbesondere, wenn das Netz sensible Entscheidungen treffen soll, z.B. im medizinischen Bereich.
- Manche Fragen sollte man keinem Computer stellen. Bei KI-Systemen ist man sehr schnell bei **Ethik und Moral**, z.B. beim autonomen Fahren.

CPEC CENTER FOR
PERSPICUOUS
COMPUTING

perspicuous /pə
ˈspɪkjʊəs/
adjective *formal*
clearly expressed and
easily understood; lucid.
able to give an account
or express an idea
clearly.




Was haben wir heute implementiert?




Welche Jobs werden im Umfeld des maschinellen Lernens gebraucht?




Kundenkontakt / Beratung / Verständnis des Problembereichs



Programmierung / Architektur



Data Analyst / Data Engineer



Human Computer Interaction

Welche Studiengänge gibt es zum Thema KI an der UdS?

- Informatik - Bachelor/Lehramt
- Data Science & AI
- Cybersecurity
- Bioinformatik
- Wirtschaftsinformatik
- Medieninformatik
- Human Computer Interaction
- ...

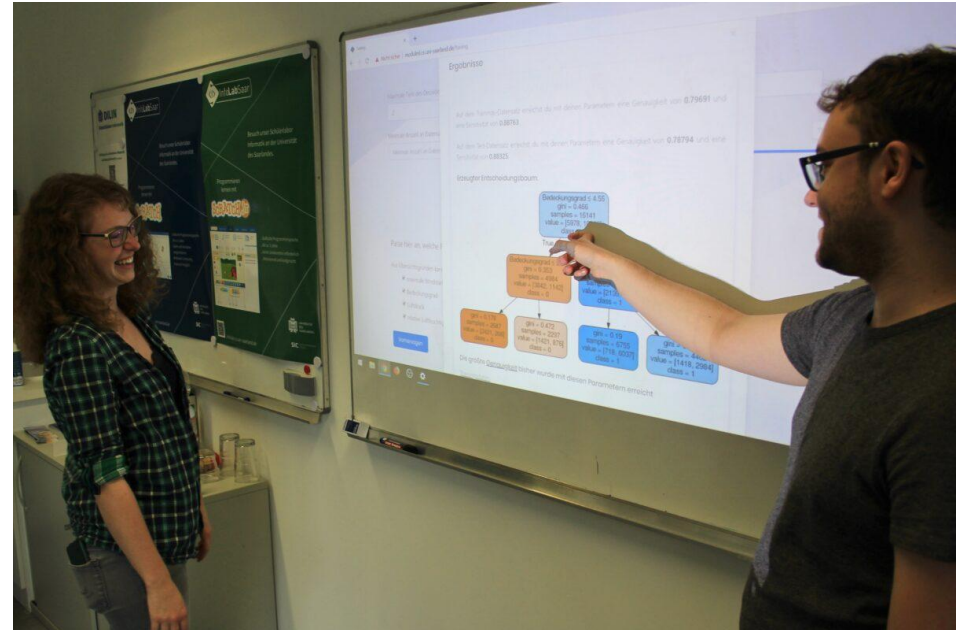


Bild: InfoLab Saar

Neuronale Netze im Studium an der Uds

Beispielstudienplan Bachelor Data Science and Artificial Intelligence

1	Programmierung 1 (9 CP)	Mathematik für Informatiker 1 (9 CP)	Ringvorlesung (2 CP)	Elements of Data Science and Artificial Intelligence (9 CP)	29
2	Programmierung 2 (9 CP)	Mathematik für Informatiker 2 (9 CP)	Statistics Lab	Anwendungsfach	31
3	Elements of Machine Learning (6 CP)	Mathematik für Informatiker 3 (9 CP)	 UNIVERSITÄT DES SAARLANDES FAKULTÄT FÜR MATHEMATIK UND INFORMATIK MODULHANDBUCH Data Science and Artificial Intelligence B vertiefungs- vorlesung DSAI (6 CP) Machine Learning		
4	Big Data Engineering (6 CP)	Projektseminar Data Science and Artificial Intelligence (9 CP)			
5	Wahlpflichtbereich (8 CP)	Stammvorlesung DSAI (9 CP)			
6	Bachelor-Seminar (9 CP)	Bachelor-Arbeit (12 CP)			

- Machine Learning (supervised, unsupervised, reinforcement, neural networks)

Elements of Data Science and Artificial Intelligence

EIDSAI

Studiensem.	Regelst.sem.	Turnus	Dauer	SWS	ECTS
1	6	every winter semester	1 semester	6	9

Modulverantwortliche/r Prof. Dr. Jörg Hoffmann
Prof. Dr. Jens Dittrich
Prof. Dr. Bernt Schiele
Prof. Dr. Vera Demberg

Dozent/inn/en Prof. Dr. Jörg Hoffmann
Prof. Dr. Jens Dittrich
Prof. Dr. Bernt Schiele
Prof. Dr. Vera Demberg

Zulassungsvoraussetzungen keine

Leistungskontrollen / Prüfungen Weekly assignments,
Exam (qualification for exam depends on performance in assignments)

Lehrveranstaltungen / SWS 4 h lectures
+ 2 h tutorial
= 6 h (weekly)

Arbeitsaufwand 90 h of classes
+ 180 h private study
= 270 h (= 9 ECTS)

Modulnote Based on exam. The exact modalities are specified by the lecturers.

Sprache English

Lernziele / Kompetenzen

Overview of challenges and methods in Data Science and AI. Basic knowledge of key concepts and algorithms.

Inhalt

Introduction to history and concepts of Data Science and AI

- Machine Learning (supervised, unsupervised, reinforcement, neural networks)
- (adversarial) Search, Planning
- Reasoning


Language Processing, Social Networks.

The exercises will cover methodological, algorithmic, as well as practical aspects. Where basic programming or scripting skills are required, the lecture and exercises will introduce these skills.


Was ihr sofort machen könnt

- Online-Kurse, z.B. [KI Campus](#) oder [3Blue1Brown](#)
- [Bundeswettbewerb Künstliche Intelligenz](#)
- [Bundeswettbewerb Informatik](#)
- [Gasthörer an der UdS](#) - ohne formale Zulassungskriterien
- [Juniorstudium an der UdS](#) - mit Bewerbung, Start im Wintersemester
- [Saar Hackathon](#): Frühjahr und Herbst in Dudweiler
- [CoderDojo Saar](#) - Teilnehmer*in / Mentor*in, jeden 4. Samstag im Monat
- [Hacksaar](#): wöchentliche Treffen in Dudweiler, hardwarenah

Ein Eintrag aus dem MNIST-Dataset



Neuronales Netzwerk für die MNIST-Aufgabe - Hidden Layer



Block 6 Neuronales Netz trainieren


```
1 # Block 6
2 # Trainingsloop
3 num_epochs = 1
4
5 print("Starte Training")
6 for epoch in range(num_epochs):
7     for batch_index, (images, labels) in enumerate(training_loader):
8         optimization_algorithm.zero_grad()
9         outputs = model(images) # Forward wird aufgerufen, wenn data durch das Model geleitet wird
10        # outputs = bis zu 64 (batch_size) Wahrscheinlichkeitsverteilungen für jeweils all 10 Ziffern
11        # [-4.8741e+00, 6.0430e+00, 1.4008e+00, 1.1718e+00, -2.7590e+00,
12        # 3.0154e-01, -4.9669e-01, 6.0514e-01, 8.4430e-01, -7.3287e-01]
13        loss = loss_function(outputs, labels)
14        loss.backward()
15        optimization_algorithm.step()
16
17        if batch_index % 100 == 0:
18            print(f'Epoch {epoch+1}/{num_epochs}, Batch {batch_index}/{len(training_loader)}, Loss: {loss.item()}')
19 print("Traning fertig!")
```

Epoch 1/1, Batch 0/938, Loss: 0.16773500014705658
 Epoch 1/1, Batch 100/938, Loss: 0.22459541261196136
 Epoch 1/1, Batch 200/938, Loss: 0.220924632645416
 Epoch 1/1, Batch 300/938, Loss: 0.2684001922687422

Welche Studiengänge gibt es zum Thema KI an der UdS?

- Informatik - Bachelor/Lehramt
- Data Science & AI
- Cybersecurity
- Bioinformatik
- Wirtschaftsinformatik
- Medieninformatik
- Human Computer Interaction

• ...



1. Neuronales Netz definieren und instantiieren

```
1 # Version 1.0
2 # Block 1
3 import torch
4 import torch.nn as nn
5
6 # Definiere das neuronale Netzwerk
7 class SimpleNN(nn.Module): # erbt von nn.Module
8     def __init__(self):
9         super(SimpleNN, self).__init__()
10        self.fc1 = nn.Linear(28*28, 128) # fcl = fully connected layer, 28x28=784 in, 128 out
11        self.relu = nn.ReLU()           # Rectified Linear Unit (gerichtetes lineares Element)
12        self.fc2 = nn.Linear(128, 10)   # f(x) = max(0, x)
13                                       # 128 in, 10 out
14
15    def forward(self, x):
16        x = x.view(-1, 28*28) # Flattening der Eingabe
17        x = self.fc1(x)
18        x = self.relu(x)
19        x = self.fc2(x)
20        return x
21
22 # Model für das Neuronale Netz instantiieren
23 model = SimpleNN()
24
```

2. - 4. Daten herunterladen, transformieren und in Batches aufteilen

```
25 # Block 2
26 from torchvision import transforms
27
28 # Lade das MNIST-Dataset und wende Transformationen an
29 transform_function = transforms.Compose([transforms.ToTensor(), transforms.Normalize((0.5,), (0.5,))])
30
31 # Block 3
32 from torchvision import datasets
33
34 training_data = datasets.MNIST(root='./data', train=True, download=True, transform=transform_function)
35 test_data = datasets.MNIST(root='./data', train=False, download=True, transform=transform_function)
36
37 # Block 4
38 from torch.utils.data import DataLoader
39
40 training_loader = DataLoader(dataset=training_data, batch_size=64, shuffle=True)
41 test_loader = DataLoader(dataset=test_data, batch_size=64, shuffle=False)
42
```

5. Verlustfunktion und Optimierungsalgorithmus definieren

```
43 # Block 5
44 import torch.optim as optim
45
46 # Verlustfunktion (Loss) und Optimierer definieren
47 loss_function = nn.CrossEntropyLoss()
48 optimization_algorithm = optim.SGD(model.parameters(), lr=0.01) # SGD = stochastic gradient descent,
49                                                                # lr = learning rate
50
```

6. Neuronales Netz trainieren

```
51 # Block 6
52 # Trainingsloop
53 num_epochs = 1
54
55 print("Starte Training")
56 for epoch in range(num_epochs):
57     for batch_index, (images, labels) in enumerate(training_loader):
58         optimization_algorithm.zero_grad()
59         outputs = model(images) # forward wird aufgerufen, wenn data durch das Model geleitet wird
60         # outputs = size zu 64 (batch_size) Mehrschichtenverteilungen für jeweils alle 10 Ziffern
61         # [-4.8741e+00, 6.0430e+00, 1.4008e+00, 1.1718e+00, -2.7590e+00,
62         # 3.0154e-01, -4.9609e-01, 6.0514e-01, 8.4439e-01, -7.3287e-01]
63         loss = loss_function(outputs, labels)
64         loss.backward()
65         optimization_algorithm.step()
66
67     if batch_index % 100 == 0:
68         print(f"Epoch {epoch+1}/{num_epochs}, Batch {batch_index}/{len(training_loader)}, Loss: {loss.item()}")
69 print("Training fertig")
70
```

7. Accuracy berechnen

```
71 # Block 7
72 # Evaluierung auf dem Testdatensatz
73 model.eval()
74 correct = 0
75 total = 0
76
77 with torch.no_grad():
78     for image, label in test_loader:
79         outputs = model(image)
80         _, predicted = torch.max(outputs.data, 1)
81         total += label.size(0)
82         correct += (predicted == label).sum().item()
83
84 accuracy = correct / total
85 print(f"Genauigkeit auf dem Testdatensatz: {accuracy * 100:.2f}%")
```