

Vorabfragen

- Sie möchten ein CNN zur Erkennung von Verkehrszeichen trainieren. Sie besitzen 300 Trainingsbilder pro Klasse.
 - Ist das ausreichend?
 - Falls nein: Was könnten Sie tun?
- Ein autonomes Fahrzeug erkennt auf einem Bild einen Fußgänger. Welche zusätzliche Information benötigt das Fahrzeug, um sicher bremsen oder ausweichen zu können?



Deep Learning, Machine Learning und Künstliche Intelligenz – SS 26

Gelesen von Prof. Dr. Daniel Gaida

Lernraum III

Inhalt

- Data Augmentation – synthetische Vergrößerung des Trainingsdatensatzes
 - Bilder
 - Text
 - Zeitreihen (future)
- Bildverarbeitung mit KI Algorithmen, die über Bildklassifikation hinausgeht
 - Objektdetektion
 - Objekttracking
 - Open-Vocabulary Objektdetektion
 - Bildsegmentierung
 - Open-Vocabulary Image Segmentation

Lernziel

Die Studierenden können Methoden der Data Augmentation für Bilder und Text umsetzen, indem sie

- Code zur Data Augmentation in Python implementieren und verstehen können, um später besser generalisierende DL/ML-Modelle trainieren zu können.

Die Studierenden können einfache Deep Learning Projekte zur Bilderkennung umsetzen, indem sie

- zwischen Objektdetektion, -tracking und –segmentierung eine geeignete Technik auswählen und
- diese mit einem Deep Learning Modell in Python umsetzen können, um später verschiedene Bilderkennungsprobleme lösen zu können.

Data Augmentation

Ziel

- Erzeugung weiterer Trainingsdaten, um ML/DL-Modelle zu erhalten, die besser generalisieren
- Durch leichte Veränderung der einzelnen Trainingsdatenpunkte werden neue, künstlich generierte, Datenpunkte erzeugt, die dem Trainingsdatensatz hinzugefügt werden.
- Dabei sind die Veränderungen so klein, dass das Label nicht verändert werden muss

- Beispiele:
 - Bilder:
 - Rotation, Translation, Farbänderung, Rauschen, ...
 - Text:
 - Satzbau umstellen, Wörter durch Synonyme ersetzen, Rechtschreibfehler einbauen, ...
 - Zeitreihen:
 - Rauschen, Frequenzveränderung, Amplitudenveränderung, ...

Data Augmentation

Weitere Ziele


- Robustheit erhöhen
 - Rechtschreibfehler, Bild- oder Tonrauschen, ...
- Klassen balancieren
 - Generiere Daten für Klassen für die man zu wenig Daten hat
- Privatsphäre/Anonymisierung
 - Generiere Daten und trainiere ausschließlich mit den synthetischen Daten bzw. stelle diesen generierten Datensatz öffentlich zur Verfügung

Data Augmentation


Bilder

Transformationen

- Spiegeln
- Rotation
- Zoom
- Translation



Original:



Rotation und Translation:



Data Augmentation

Bilder

Keras Layer

- `layers.RandomFlip("horizontal")`
- `layers.RandomRotation(0.1)`
- `layers.RandomZoom(0.3)`
- `layers.RandomTranslation(height_factor=0.1, width_factor=0.1)`

```
keras.Sequential([  
    layers.RandomRotation(0.1),  
    layers.RandomTranslation(height_factor=0.1, width_factor=0.1)  
])
```


s. Notebook [01_fminst_data_augmentation.ipynb](#)

Data Augmentation

Bilder - Übung

Training eines [CNN mit Data Augmentation](#) Schichten in keras:

- Nutzen Sie eine GPU und fügen Sie weitere Data Augmentation Schichten zu dem CNN hinzu
 - Bspw.:
 - Änderung des Kontrasts
 - Quelle: https://www.tensorflow.org/tutorials/images/data_augmentation
- Bei Bedarf auch ohne Data Augmentation trainieren, um einen Vergleich zu haben
 - Ab Epoche 8 startet leichtes Overfitting
 - Genauigkeit bei Train und Val aber > 91 %
- Auf was muss man bei der Nutzung von Data Augmentation achten?
 - Denken Sie dabei bspw. an den MNIST Datensatz...



Data Augmentation

Bilder

Albumentations, <https://albumentations.ai/>

- Daten werden Batch für Batch augmentiert. Während der eine Batch für das Training des CNNs genutzt wird, wird der nächste Batch augmentiert und dem CNN zur Verfügung gestellt. Das CNN wird nicht verändert.

3. Albumentations Transformationen definieren

```
transforms = A.Compose([  
    A.HorizontalFlip(p=0.5),  
    A.Rotate(limit=10, p=0.5),  
    A.RandomBrightnessContrast(p=0.2),  
])
```



Data Augmentation

Bilder – Übung mit Albumentations

Öffnen Sie das Notebook [03_fm1nist_albumentations.ipynb](#)

- Welche weiteren Data Augmentation Transformationen können Sie hinzufügen?
 - <https://albumentations.ai/docs/3-basic-usage/image-classification/#mnist-style-pipeline-grayscale-28x28>
- Lassen Sie sich bei Bedarf diese Zeile von einer LLM erklären:

```
train_ds = train_ds.shuffle(1000).map(process_data,  
num_parallel_calls=tf.data.AUTOTUNE).batch(batch_size).prefetch(tf.data.AUTOTUN  
E)
```

Data Augmentation

Text – Nutzung von LLMs (Stand der Technik bis 2023)

Transformationen

- Back Translation:
 - Übersetzen des Textes in eine andere Sprache und dann zurück in die Originalsprache.
- Mask-and-Infill
 - Maskiere Teile des Textes und lasse ein LLM diese ersetzen.
 - Beispiel:
 - Der Kunde war [MASK] zufrieden.
 - → Der Kunde war außerordentlich zufrieden.
- Contextual Word Replacement
 - Wörter werden durch Synonyme ersetzt, allerdings abhängig vom Kontext (ein LLM entscheidet)



Data Augmentation

Text – Aktueller Stand der Technik

Transformationen

- LLM-basierte Paraphrasierung
 - Prompt:
 - Erzeuge 10 semantisch äquivalente Varianten.
 - Beispiel:
 - Original: „Die Lieferung kam zu spät.“
 - Varianten: „Die Zustellung erfolgte verspätet.“, "Das Paket traf später als erwartet ein.,
- Synthetic Data Generation
 - Statt bestehende Daten zu verändern: LLM erzeugt komplett neue Beispiele.
 - Beispiel:
 - Intent: Passwort zurücksetzen
 - LLM generiert 1000 neue Nutzeranfragen
 - unterschiedliche Schreibweisen
 - unterschiedliche Detailgrade

Data Augmentation

Text – Aktueller Stand der Technik

Retrieval-basierte Augmentation

- Idee:
 - Suche ähnliche Dokumente.
- Dann:
 - extrahiere Muster
 - generiere neue Varianten
- Wichtig, damit die generierten Dokumente auch wirklich typisch für die Klasse sind
- Beispiel:
 - Wir haben zu wenig E-Mails für Klasse Christentum
 - Generation von weiteren E-Mails dieser Klasse durch ein LLM durch Übergabe aller Mails der Klasse an das LLM.

Data Augmentation

Text - Übung

Öffnen Sie das Notebook: [07 text data augmentation.ipynb](#)

Generieren Sie weitere Nachrichten einer Klasse Ihrer Wahl und prüfen Sie die Sinnhaftigkeit und Passgenauigkeit der generierten Nachrichten.

Bei Bedarf:

- Verbessern Sie den Prompt

Data Augmentation

Text – Qualitätskontrolle

Nach der Generierung müssen Sie die Qualität der Sätze prüfen lassen:

- Semantic Similarity Filter
 - Embeddings vergleichen: Cosine Similarity

- NLI-basierte Validierung (Natural Language Inference)
 - Prüft ob der generierte Satz aus dem ursprünglichen Satz folgt (Entailment) oder diese widersprüchlich sind (Contradiction)
 - Widersprüchliche Sätze könnten eine hohe Cosine similarity haben, wenn sie sich nur um ein Wort unterscheiden („nicht“)

- Diversity Filtering
 - Verhindert:
 - Duplikate, Near-Duplicates
 - Typisch: Clustering der Embeddings

Übung: Embedding Modell angeben und ausprobieren

- Cosine similarity liefert Werte zwischen -1 und 1 zurück (üblicherweise aber eher zwischen 0 und 1)

```
# this cell is optional - not needed for the notebook to run
# you can play with this if you want to test how close two embedding vector are
embedding_1 = embed_model.get_text_embedding("Hello, my name is Daniel")
embedding_2 = embed_model.get_text_embedding("How are you?")

# Compute dot product similarity
similarity = sum(a * b for a, b in zip(embedding_1, embedding_2))
print(similarity)
```

0.8202128970159881

```
# this cell is optional - not needed for the notebook to run
# you can play with this if you want to test how close two embedding vector are
embedding_1 = embed_model.get_text_embedding("Hello, my name is Daniel")
embedding_2 = embed_model.get_text_embedding("Hello, my name is not Daniel")

# Compute dot product similarity
similarity = sum(a * b for a, b in zip(embedding_1, embedding_2))
print(similarity)
```

0.9513346940599776

Übung: Embedding Modell angeben und ausprobieren

```
import numpy as np
```

KING - MAN + WOMAN = ~~QUEEN~~
≈ KING ?

```
# Convert lists to NumPy arrays before performing arithmetic
```

```
embedding_1_np = np.array(embed_model.get_text_embedding("King")) -  
np.array(embed_model.get_text_embedding("Man")) +  
np.array(embed_model.get_text_embedding("Woman"))
```

```
embedding_2_np = np.array(embed_model.get_text_embedding("Queen"))
```


```
# Compute dot product similarity using NumPy's dot function
```

```
similarity = np.dot(embedding_1_np, embedding_2_np)
```

```
print(similarity)
```

Übung: Embedding Modell angeben und ausprobieren

What does it give you for:
Martini - Gin + Whiskey?




See how stupid AI is?


"Cocktail"*





Yeah! Everybody knows that
that's a Manhattan!



Yeah. I can't believe it.
You trained it on the entire
Wikipedia, and it still doesn't
know how to mix a Manhattan!



Guess I need to train it
on some cocktail books.



*I briefly tested it. With a Continuous Skip-Gram algorithm trained on Google News (100 billion tokens) I got for *gin is to Martini what whiskey is to X*:
1. signature_cocktails, 2. Cocktails, 3. Cocktail, 4. Vodka_Martini, 5. cocktails
CC BY 4.0 Florian Huber

Data Augmentation

Text – Qualitätskontrolle - Übung

Öffnen Sie das Notebook [04_HF_EmbeddingModel_test.ipynb](#)

Beachten Sie den „Restart Session“ Button am Ende der Ausgaben der ersten Zelle.

Vergleichen Sie unterschiedliche Texte über die cosine similarity ihrer Embedding Vektoren.
Überprüfen Sie ob Negationen eine hohe similarity haben.

Untersuchen Sie bei Bedarf unterschiedliche Embedding Modelle


Data Augmentation

Text – Qualitätskontrolle - Übung

Prüfen Sie wie gut mit LLM generierter Text ([07 text data augmentation.ipynb](#)) zu den Texten der Klasse passt.

Notebook: [08 embedding visualization.ipynb](#)

Sie können sich das trainierte UMAP Modell und die Embeddings [hier](#) herunterladen und in google colab hochladen – das spart 3-4 Minuten Ausführungszeit des Notebooks.



Data Augmentation

Zeitreihen

<u>Transformation</u>	<u>Idee</u>
Jittering	kleines Gaußsches Rauschen hinzufügen
Scaling	Werte leicht skalieren
Time Warping	Zeitachse lokal dehnen oder stauchen
Window Slicing	zufälligen Ausschnitt verwenden

- Wichtig: Transformationen müssen die **zeitliche Struktur** erhalten.
- Gute Augmentation erzeugt realistische Variationen, ohne die Bedeutung der Zeitreihe zu verändern.
- Tool: tsaug
 - <https://tsaug.readthedocs.io/en/stable/>

Data Augmentation

Zusammenfassung

- Data Augmentation vergrößert den Trainingsdatensatz durch leichte Variationen der Trainingsdatenpunkte
- Data Augmentation niemals auf Testdaten anwenden!
- Automatisierte Qualitätskontrolle wichtig
 - Prüft, ob der generierte Datenpunkt in der gleichen Klasse wie sein Original liegt


Lernraum III

Inhalt


- Data Augmentation – synthetische Vergrößerung des Trainingsdatensatzes
 - Bilder
 - Text
 - Zeitreihen (future)
- **Bildverarbeitung mit KI Algorithmen, die über Bildklassifikation hinausgeht**
 - Objektdetektion
 - Objekttracking
 - Open-Vocabulary Objektdetektion
 - Bildsegmentierung
 - Open-Vocabulary Image Segmentation

Objektdetektion


Ziel: Benennung der Objekte in der Szene



Objektdetektion



Objektdetektion




- YOLOv8
- Erkennt nur 80 verschiedene Objektkategorien (Autos, Fahrräder, Tiere, Regenschirme, ...)



Objektdetektion

Deep Learning Modell

- YOLO – You only look once
 - Redmon, J., & Farhadi, A. (2015). You only look once: Unified, real-time object detection. In Proc. IEEE CVPR (pp. 779-788).
- YOLO26 – plug & play
 - <https://github.com/ultralytics/ultralytics>
- Fertig trainierte Modelle in unterschiedlichen Größen herunterladbar
- Trainiert an COCO Datensatz
 - 80 verschiedene Objektkategorien (Autos, Fahrräder, Tiere, Regenschirme, ...)



Objektdetektion

Bevor Sie ein Deep Learning Modell selbst erstellen und trainieren:

- Es gibt sehr viele an sehr großen Datensätzen trainierte Modelle, die Sie herunterladen und direkt nutzen können
- Sie können dieses Modell auch als initiales Modell nutzen, welches Sie mit Ihren eigenen Daten verbessern können
 - Transfer Learning
 - Knowledge Distillation
- YOLO26 als Beispiel
- <https://huggingface.co/models>
- <https://modelzoo.co/>

Objektdetektion

Trainingsdatensatz

```
0 0.0414228 0.659696 0.0828456 0.299007
11 0.0199709 0.268372 0.0397828 0.0651804
0 0.349451 0.584807 0.152251 0.418149
0 0.913659 0.58147 0.172332 0.45871
```

Trainingsdaten

- Bilder


Markieren der Bilder (Labeling)

- Um jedes zu detektierende Objekt ist ein Rahmen zu zeichnen
- Pro Bild können mehrere Objekte markiert werden

Label

- Koordinaten des Rahmens
- Klasse des Objekts
- Für jedes Bild stehen Label in einer txt-Datei

Use your mouse to drag a box around an object to add a label. Then click **Save labels** to advance to the next item.



<https://www.edgeimpulse.com/blog/3-ways-to-do-ai-assisted-labeling-for-object-detection>

Objektdetektion mit Deep Learning

Kostenlose Tools, die das Labeling beschleunigen


- <https://www.cvat.ai/>
- <https://roboflow.com/#annotate>
- <https://pypi.org/project/labelImg/>
- ...

Bereits gelabelte Datensätze (Erster Schritt):

- <https://paperswithcode.com/datasets?task=object-detection&page=1> (233 Object Det. Datensätze)
- Kaggle, roboflow, ...
- <https://datasetsearch.research.google.com/>
- Wenn nicht genau der richtige Datensatz dabei ist, hilft es meistens dennoch das Modell auf dem ähnlichsten Datensatz zu trainieren und das Modell dann auf einem eigenen Datensatz weiter zu trainieren (Transfer Learning, finetuning)

Objektdetektion mit Deep Learning



Training – sehr viele Bilder und deren Label



0 0.0414228 0.659696 0.0828456 0.299007
11 0.0199709 0.268372 0.0397828 0.0651804
0 0.349451 0.584807 0.152251 0.418149
0 0.913659 0.58147 0.172332 0.45871

Objektdetektion mit Deep Learning

Inferenz



YOLOv11 Objektdetektion testen

`pip install ultralytics`

`from ultralytics import YOLO`


`model = YOLO("yolo26n.pt") # load an official model`

`# Predict with the model`

`results = model("https://ultralytics.com/images/bus.jpg")`

<https://docs.ultralytics.com/tasks/detect/>

Siehe Notebook: [06_objektdetektion_yolo26.ipynb](#)



Lernraum III

Inhalt

- Data Augmentation – synthetische Vergrößerung des Trainingsdatensatzes
 - Bilder
 - Text
 - Zeitreihen (future)
- **Bildverarbeitung mit KI Algorithmen, die über Bildklassifikation hinausgeht**
 - Objektdetektion
 - **Objekttracking**
 - Open-Vocabulary Objektdetektion
 - Bildsegmentierung
 - Open-Vocabulary Image Segmentation


Objekt Tracking

Objekt Tracking

- Eindeutige Objekt Detektion von beweglichen Objekten über eine Sequenz von Frames

YOLO26 hat Objekt Tracking integriert

<https://docs.ultralytics.com/modes/track/>



<https://github.com/ifzhang/ByteTrack>


Sehr gutes Tutorial von Roboflow zu Objekt Tracking mit YOLOv8 (14 Min.):

https://www.youtube.com/watch?v=Mt9iHFd0_Bo


Objekt Tracking

Vorgehensweise:

- Tracking-by-Detection
 - Objekt Detektion (bspw. mit YOLO)
 - Tracking der detektierten Objekte
 - Kalman Filter prädiziert wo Objekt in nächstem Frame sein könnte. In dieser Region wird dann für das nächste Frame Objekt Detektion ausgeführt.




<https://github.com/ifzhang/ByteTrack>




Objekt Tracking

Vorgehensweise:

- Tracking-by-Detection
 - Objekt Detektion (bspw. mit YOLO)
 - Tracking der detektierten Objekte
 - Kalman Filter prädiziert wo Objekt in nächstem Frame sein könnte. In dieser Region wird dann für das nächste Frame Objekt Detektion ausgeführt.
 - Re-Identifikation (ist das Objekt noch das gleiche?)



<https://github.com/ifzhang/ByteTrack>



30.06.2026

Seite 38


A. Patel et al., Motion-compensated online object tracking for activity detection and crowd behavior analysis, The visual Computer, 2022

Technology
Arts Sciences
TH Köln

Objekt Tracking

In YOLO26 integriert („State of the Art“ des Objekt Trackings):

- ByteTrack, <https://github.com/ifzhang/ByteTrack>
- Beibehalten von Bounding Boxen, die temporär nur einen geringen Score erhalten



Y. Zhang et al., ByteTrack: Multi-Object Tracking by Associating Every Detection Box, 2022

- BoT-SORT, <https://github.com/NirAharon/BoT-SORT>
 - Erweiterung von ByteTrack um Kompensation der Bewegung der Kamera, verbesserter Zustandsvektor des Kalman Filters, ...

YOLO26 Objekttracking testen

```
from ultralytics import YOLO
```

```
model = YOLO("yolo26n.pt") # Load an official Detect model
```

```
# Perform tracking with the model with ByteTrack
```

```
results = model.track("https://youtu.be/LNwODJXcvt4", show=True, tracker="bytetrack.yaml")
```

<https://docs.ultralytics.com/modes/track/>

s. Notebook: [09_objekttracking_yolo26.ipynb](#)

Lernraum III

Inhalt

- Data Augmentation – synthetische Vergrößerung des Trainingsdatensatzes
 - Bilder
 - Text
 - Zeitreihen (future)
- **Bildverarbeitung mit KI Algorithmen, die über Bildklassifikation hinausgeht**
 - Objektdetektion
 - Objekttracking
 - **Open-Vocabulary Objektdetektion**
 - Bildsegmentierung
 - Open-Vocabulary Image Segmentation

Objekt Detektion von beliebigen Objektkategorien

- Algorithmen der Objekt Detektion funktionieren nur für die Objektkategorien für die sie trainiert wurden
- YOLO wurde trainiert mit COCO Datensatz
 - 80 verschiedene Objektkategorien (Autos, Fahrräder, Tiere, Regenschirme, ...)
- Mit Trainingsdaten von weiteren Objektkategorien können Sie auch diese detektieren
- Was ist, wenn Sie „beliebige“ Objektkategorien detektieren möchten?
 - Open-Vocabulary Objekt Detektion
 - Trainiert mit Millionen von Bildern aus dem Internet und deren Bildbeschriftungen
- YOLOE - Real-Time Seeing Anything
 - <https://docs.ultralytics.com/models/yoloe>

Objekt Detektion von beliebigen Objektkategorien

- Open-Vocabulary Objekt Detektion
- <https://github.com/ailab-cvc/yolo-world>



Objekt Detektion von beliebigen Objektkategorien

```
from ultralytics import YOLO
```

```
model = YOLO("yoloe-11s-seg.pt")           # Initialize a model
```

```
model.set_classes(["person", "bus"])        # Define custom classes
```

```
results = model.predict("path/to/image.jpg") # Run inference to detect your custom classes
```

```
results[0].show()                           # Show results
```


s. Notebook [05_AppObjectDetection.ipynb](#)

Lernraum III

Inhalt


- Data Augmentation – synthetische Vergrößerung des Trainingsdatensatzes
 - Bilder
 - Text
 - Zeitreihen (future)
- **Bildverarbeitung mit KI Algorithmen, die über Bildklassifikation hinausgeht**
 - Objektdetektion
 - Objekttracking
 - Open-Vocabulary Objektdetektion
 - **Bildsegmentierung**
 - Open-Vocabulary Image Segmentation

Bildsegmentierung



Bildsegmentierung

- Es gibt keine objektive Definition einer „richtigen“ Segmentierung!
- Segmentierung wird durch Menschen vorgegeben




Subject 1

Subject 2

Subject 3

Bildsegmentierung



Bildsegmentierung

Trainingsdaten

Eingangsdaten




Ausgangsdaten



Quelle für Trainingsdaten: <https://paperswithcode.com/datasets?task=semantic-segmentation> (261 Datensätze)

Bildsegmentierung mit Deep Learning

Training des Deep Learning Modells (bspw. Autoencoder)




Bildsegmentierung mit Deep Learning

Instance Segmentation vs. Semantic Segmentation


<https://blog.roboflow.com/difference-semantic-segmentation-instance-segmentation/>




Image Recognition



Semantic Segmentation



Object Detection



Instance Segmentation

Bildsegmentierung mit Deep Learning


YOLO26 kann auch Instance Segmentation (<https://docs.ultralytics.com/tasks/segment/>)

Gutes Tutorial zu YOLOv8 zu Image Segmentation und Objekt Detektion, nur Inferenz (13 Min.)

<https://www.youtube.com/watch?v=75LI9MI9eEo>

```
from ultralytics import YOLO  
model = YOLO("yolo26n-seg.pt") # load a model  
# Predict with the model  
results = model("https://ultralytics.com/images/bus.jpg")
```

s. Notebook: [06_objektdetektion_yolo26.ipynb](#)



Bildsegmentierung

Instance Segmentation mit YOLOv8



Lernraum III


Inhalt

- Data Augmentation – synthetische Vergrößerung des Trainingsdatensatzes
 - Bilder
 - Text
 - Zeitreihen (future)
- **Bildverarbeitung mit KI Algorithmen, die über Bildklassifikation hinausgeht**
 - Objektdetektion
 - Objekttracking
 - Open-Vocabulary Objektdetektion
 - Bildsegmentierung
 - **Open-Vocabulary Image Segmentation**

Open-Vocabulary Image Segmentation

Segment Anything Modell (SAM 3)

- github.com/facebookresearch/segment-anything
- <https://docs.ultralytics.com/models/sam-3>
- Foundation Modell für Bildsegmentierung; Promptable
- FastSAM (<https://docs.ultralytics.com/models/fast-sam/>)
 - YOLOv8 Segmentierungsmodell und anschließend Fokus auf die gewünschten Begriffe
- Grounded Segment Anything
 - Grounding DINO (Open-Vocabulary Objekt Detektion) – lokalisiert die Objekte; geg. Prompt
 - <https://github.com/IDEA-Research/Grounding-DINO-1.5-API>
 - Segment Anything Modell – segmentiert die lokalisierten Objekte
 - <https://github.com/IDEA-Research/Grounded-SAM-2>



Open-Vocabulary Image Segmentation

```
from ultralytics import FastSAM

# Define an inference source
source = "path/to/bus.jpg"

# Create a FastSAM model
model = FastSAM("FastSAM-s.pt") # or FastSAM-x.pt

# Run inference on an image
everything_results = model(source, device="cpu", retina_masks=True, imgsz=1024,
conf=0.4, iou=0.9)

# Run inference with texts prompt
results = model(source, texts="a photo of a dog")
```


YOLOv8 testen – auf dem Smartphone



The banner features the Ultralytics YOLOv8 logo on the left, followed by the text 'YOLOv8.2' and 'Unleashing Next-Gen AI Capabilities'. A yellow button labeled 'Discover more' is positioned below the text. To the right, a list of features is displayed with corresponding icons: a laptop for 'YOLOv9 training and deployment', binoculars for 'Advanced tracking with YOLOv8-OBB', a gear for 'Zero-shot promptable YOLO-Worldv2 models', a speedometer for '40% faster ultralytics import speed', and a Raspberry Pi for 'YOLOv8.2 with Raspberry Pi 5 CI and tutorials'. On the far right, there is a QR code and the text 'Download the App', along with buttons for 'GET IT ON Google Play' and 'Download on the App Store'.

ultralytics
YOLOv8

YOLOv8.2

Unleashing Next-Gen AI Capabilities

Discover more

- YOLOv9 training and deployment
- Advanced tracking with YOLOv8-OBB
- Zero-shot promptable YOLO-Worldv2 models
- 40% faster ultralytics import speed
- YOLOv8.2 with Raspberry Pi 5 CI and tutorials

Download the App

GET IT ON
Google Play

Download on the
App Store

Entwicklung der Bilderkennung mit Deep Learning Modellen

Generation

CNN

YOLO

ByteTrack

YOLO-Seg

SAM 3

Vision-Language-Modelle

Generative Vision Models

Fähigkeit

Bildklassifikation

Objektdetektion

Objekttracking

Segmentierung

Prompt-basierte Segmentierung

Offene Objekterkennung (GPT-4o, ...)

Bildverstehen und Bildgenerierung

Generative Vision Models - Vision Banana


Bildgenerierung und -verstehen

- Gabeur, V. et al., Image Generators are Generalist Vision Learners, **2026**
- “Vision Banana is a SOTA unified model for both image understanding and generation.”
- “Generative vision pretraining is an effective paradigm for visual understanding.”
- “Image generation serves as a universal interface for diverse vision tasks.”
- S. Beispiele in <https://vision-banana.github.io/#capabilities>

Objektdetektion, -tracking und -segmentierung

Zusammenfassung

- Mit YOLO-Modellen von Ultralytics kann man viele Bilderkennungs-Anwendungen recht einfach starten



Nächste Vorlesung und Fragen

- Trainingsstrategien (Strategy for DL Troubleshooting)
- Fragen?