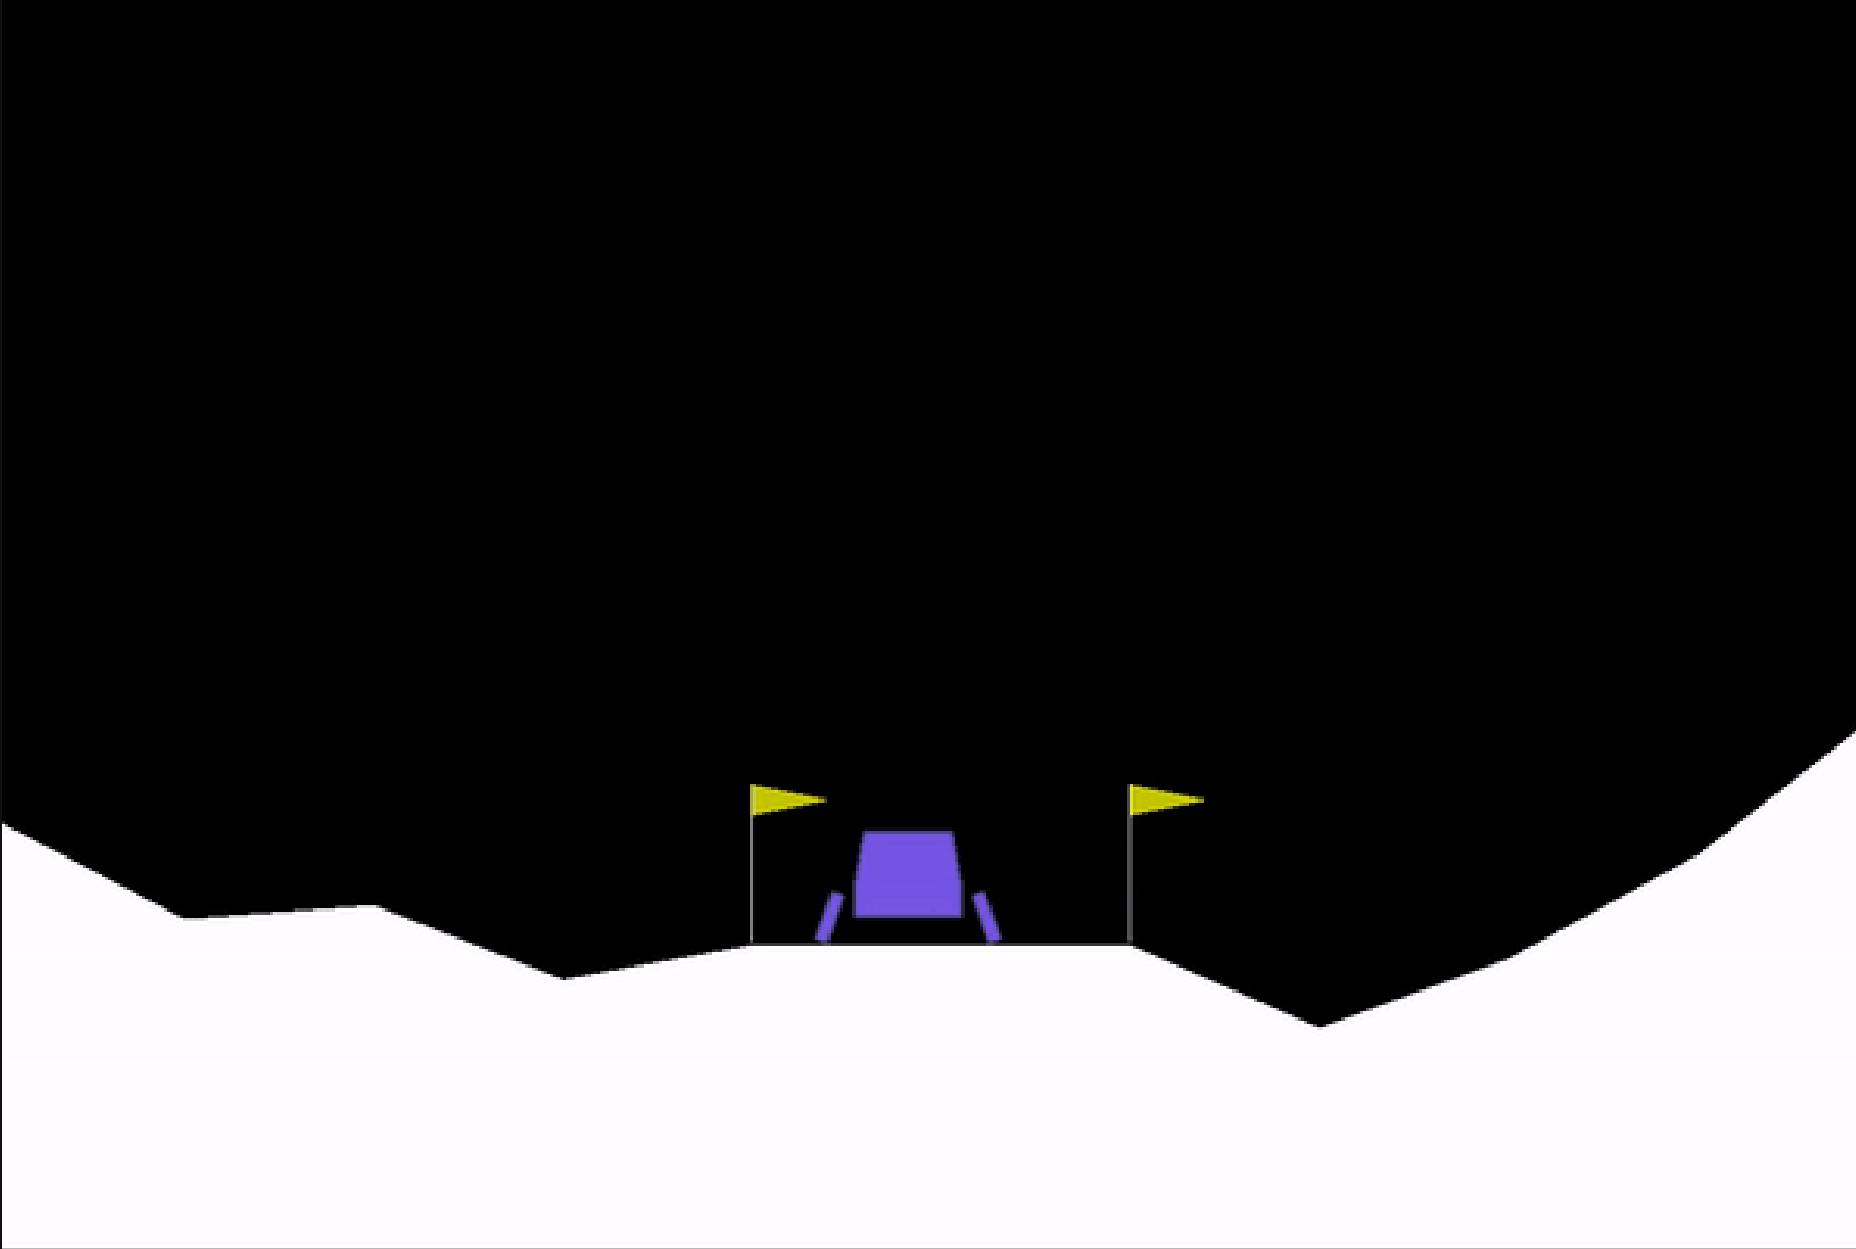


Optimieren



Optimieren



Optimieren



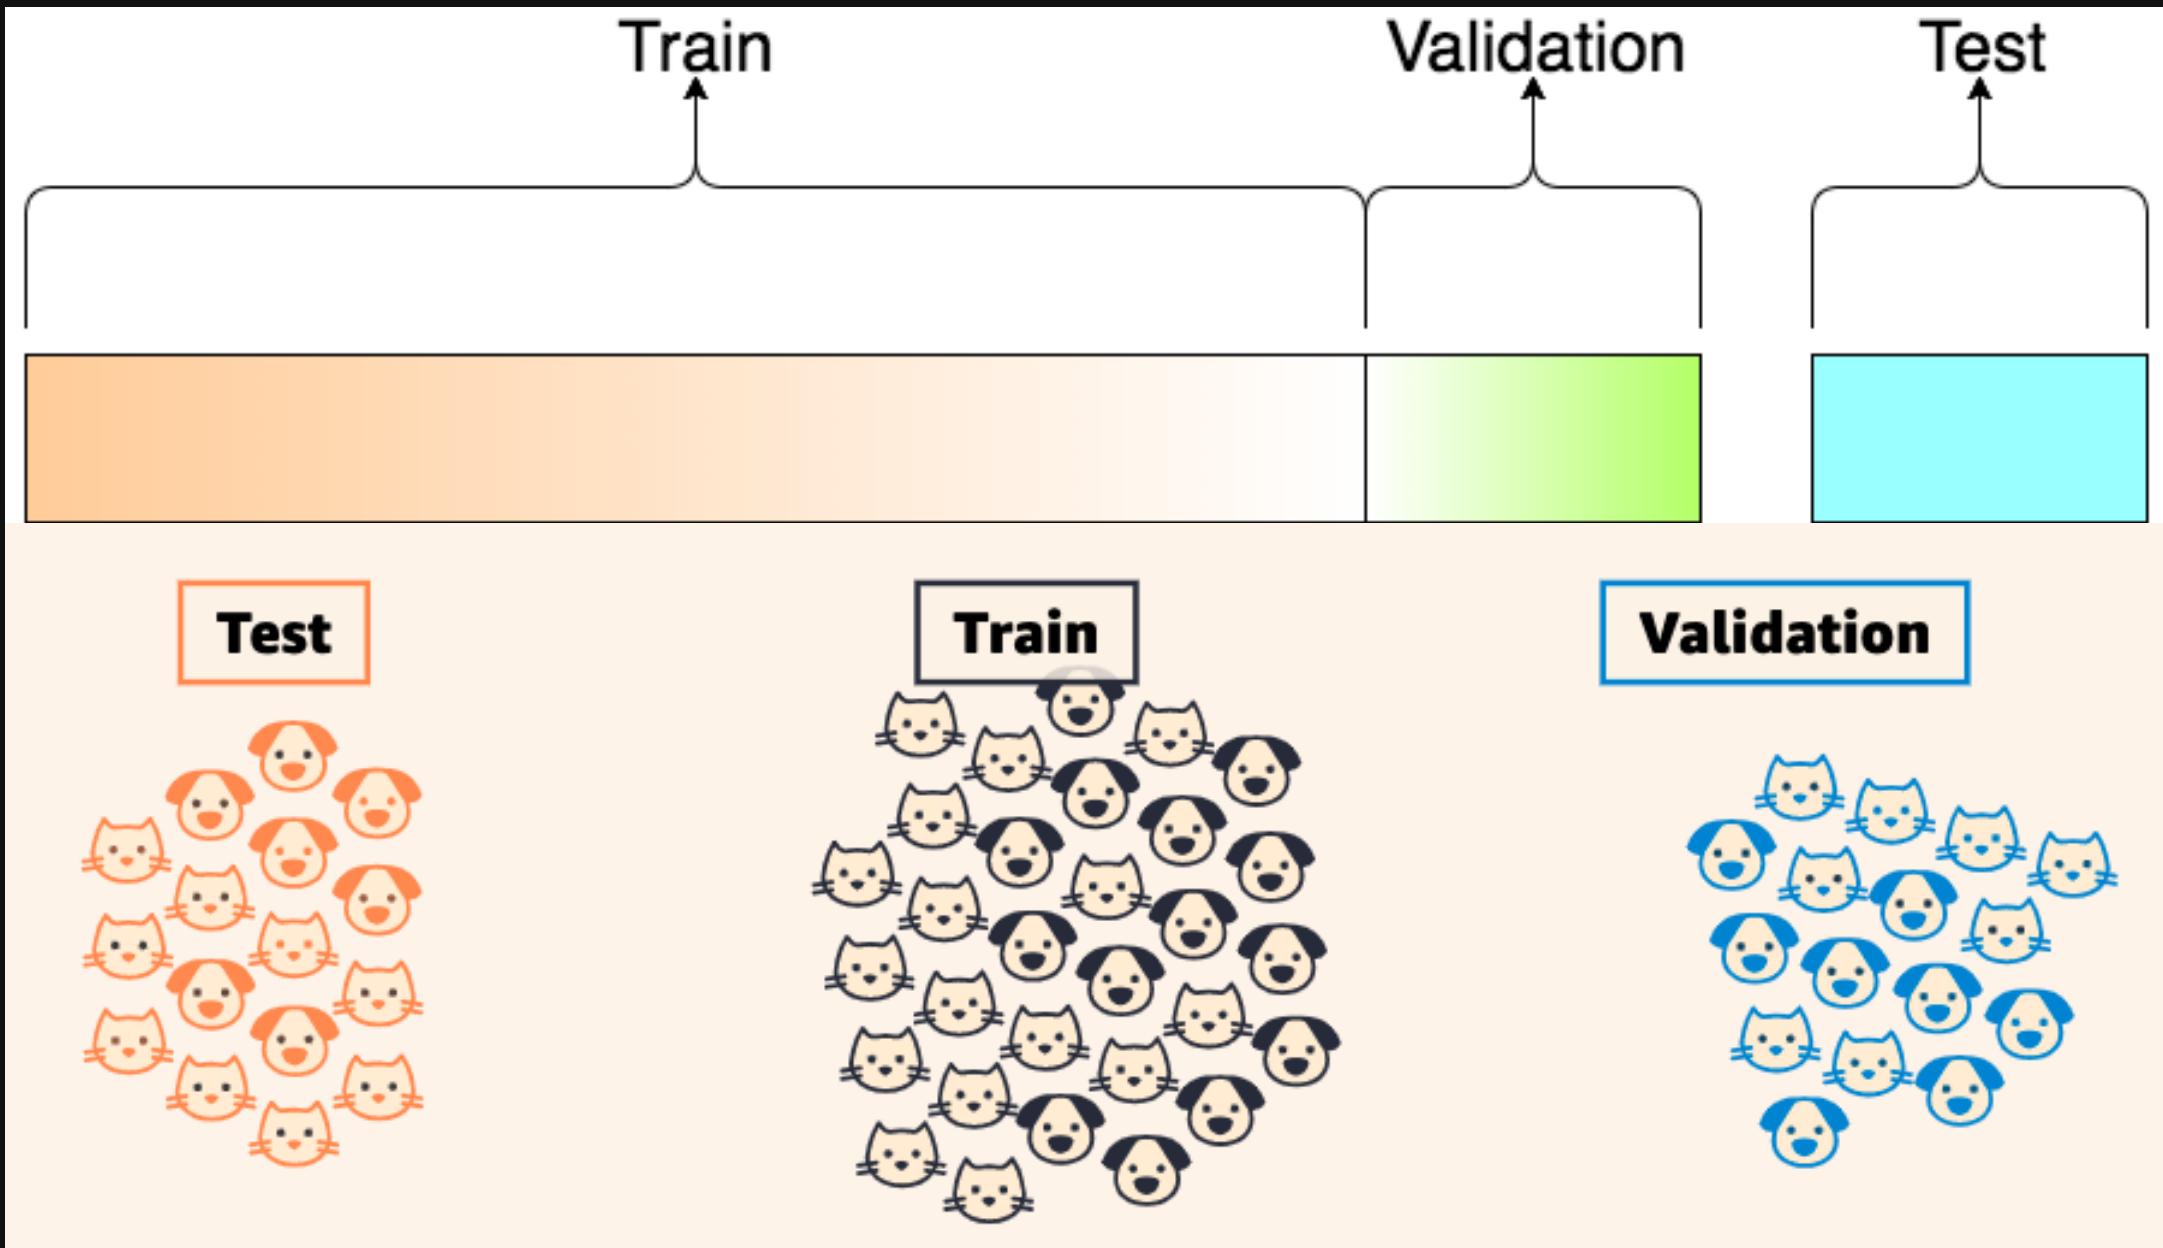
Modell auf unbekannten Daten optimieren
aber
Testset erst ganz zum Schluss verwenden

Modell auf unbekannten Daten optimieren
aber
Testset erst ganz zum Schluss verwenden

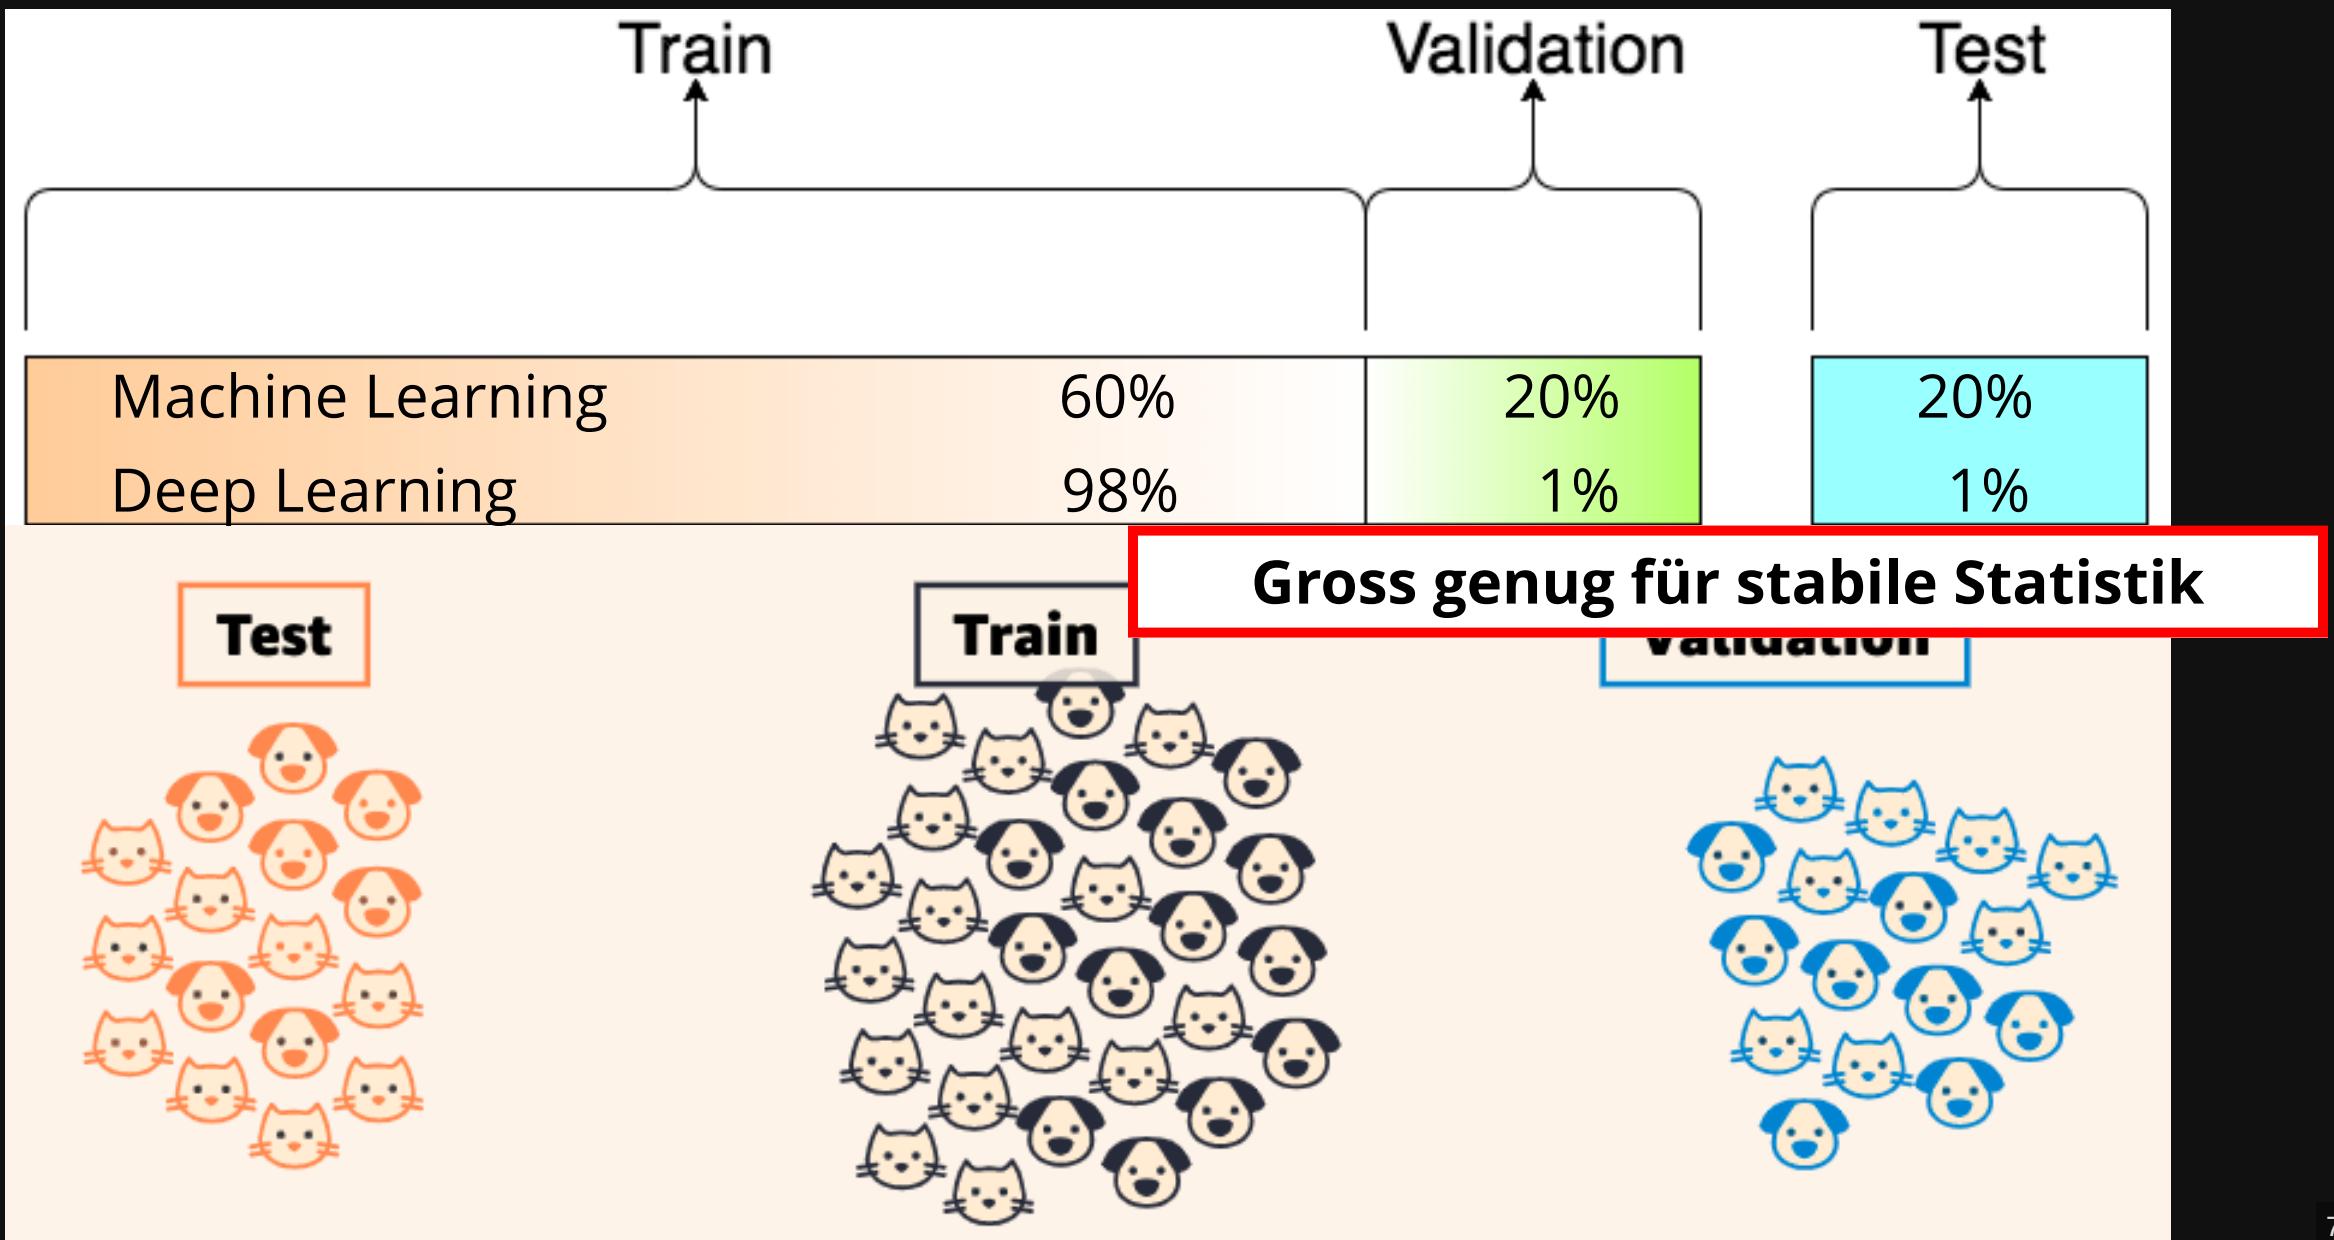
Weiteres Datenset absplitten

Train-Test-Valid Split

Train-Test-Valid Split

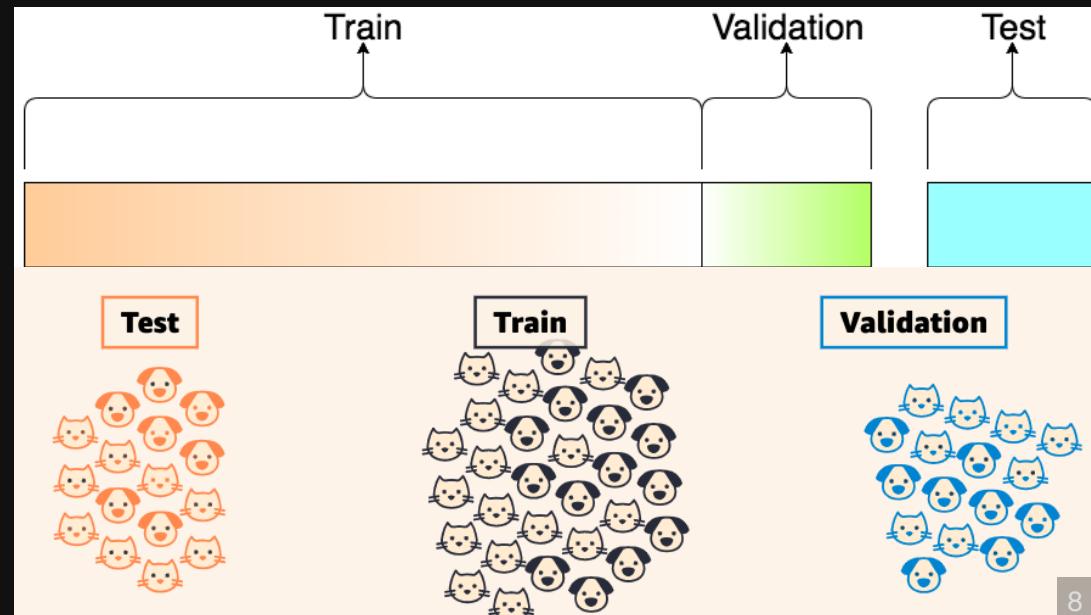


Train-Test-Valid Split



Train-Test-Valid Split

1. verschiedene Settings wählen (Hyperparameter / Architektur)
2. für wenige Epochen trainieren
3. Leistung auf Validationsdaten vergleichen
4. Setting mit bester Leistung voll trainieren
5. Trainiertes Modell auf Testset Evaluieren



Train-Test-Valid Split

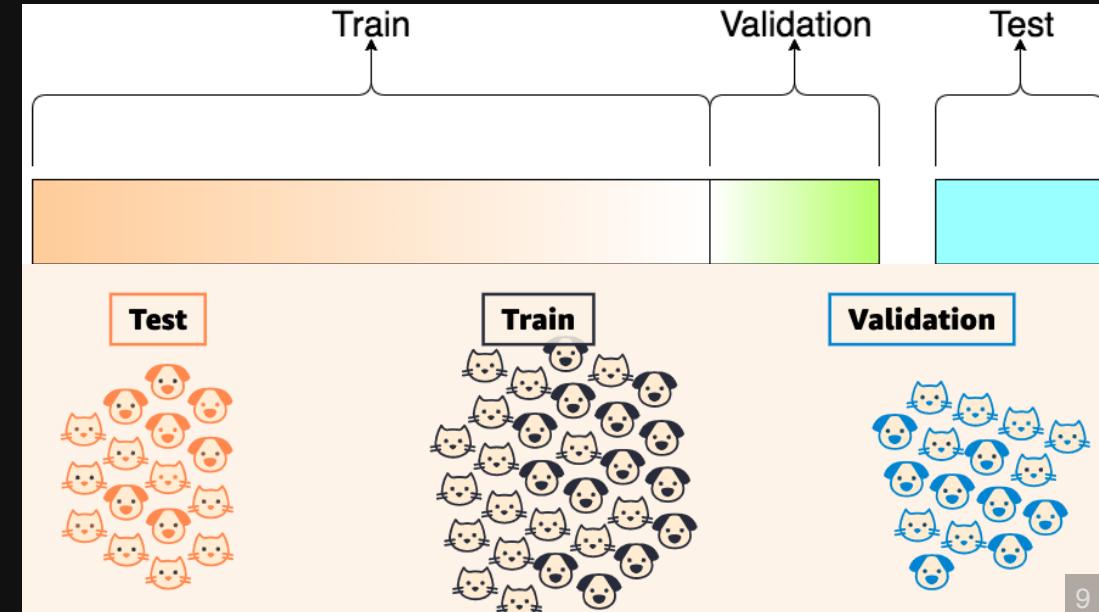
1. verschiedene Settings wählen (Hyperparameter / Architektur)
2. für wenige Epochen trainieren
3. Leistung auf Validationsdaten vergleichen
4. Setting mit bester Leistung voll trainieren
5. Trainiertes Modell auf Testset Evaluieren

```
from torch.utils.data import random_split
train_ratio, valid_ratio = 0.8, 0.2

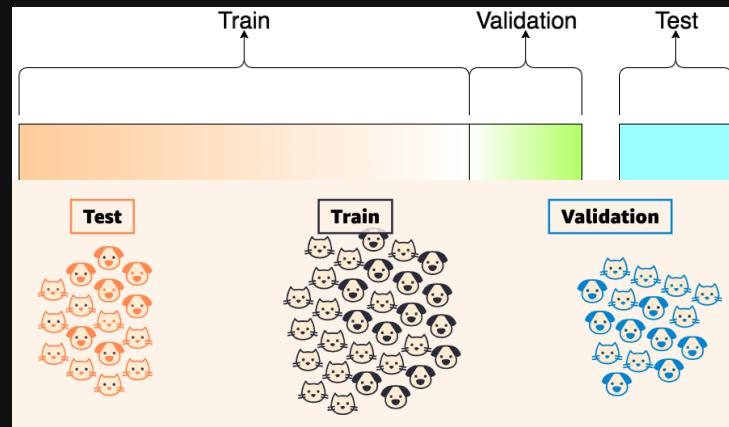
# Gesamteanzahl der Trainingsdaten
N_training = len(training_data)

# Berechne die Anzahl der Beispiele für jeden Split
train_size = int(train_ratio * N_training)
valid_size = N_training - train_size

# Teile den Trainingsdatensatz in Train und Valid auf
train_data, valid_data = random_split(training_data,
                                      [train_size, valid_size])
```



Train-Test-Valid Split



1. verschiedene Settings wählen (Hyperparameter / Architektur)
2. für wenige Epochen trainieren
3. Leistung auf Validationsdaten vergleichen
4. Setting mit bester Leistung voll trainieren
5. Trainiertes Modell auf Testset Evaluieren

```
torch.utils.data import random_split
ratio, valid_ratio = 0.8, 0.2

# Anzahl der Trainingsdaten
N_training = len(training_data)

# Schneide die Anzahl der Beispiele für jeden Split
train_size = int(train_ratio * N_training)
valid_size = N_training - train_size

# Teile den Trainingsdatensatz in Train und Valid auf
train_data, valid_data = random_split(training_data,
                                       [train_size, valid_size])
```

```
1 import tensorflow as tf
2 from sklearn.model_selection import train_test_split
3 valid_ratio = 0.2
4
5 input_data = your_input_data
6 labels = your_labels
7
8 input_train, input_valid, labels_train, labels_valid =
9         train_test_split(input_data, labels, test_size=valid_ratio, random_st
10
11 # Create TensorFlow Datasets
12 train_dataset = tf.data.Dataset.from_tensor_slices((input_train, labels_train
13 valid_dataset = tf.data.Dataset.from_tensor_slices((input_valid, labels_valid))
```

Hyperparameter



Hyperparameter

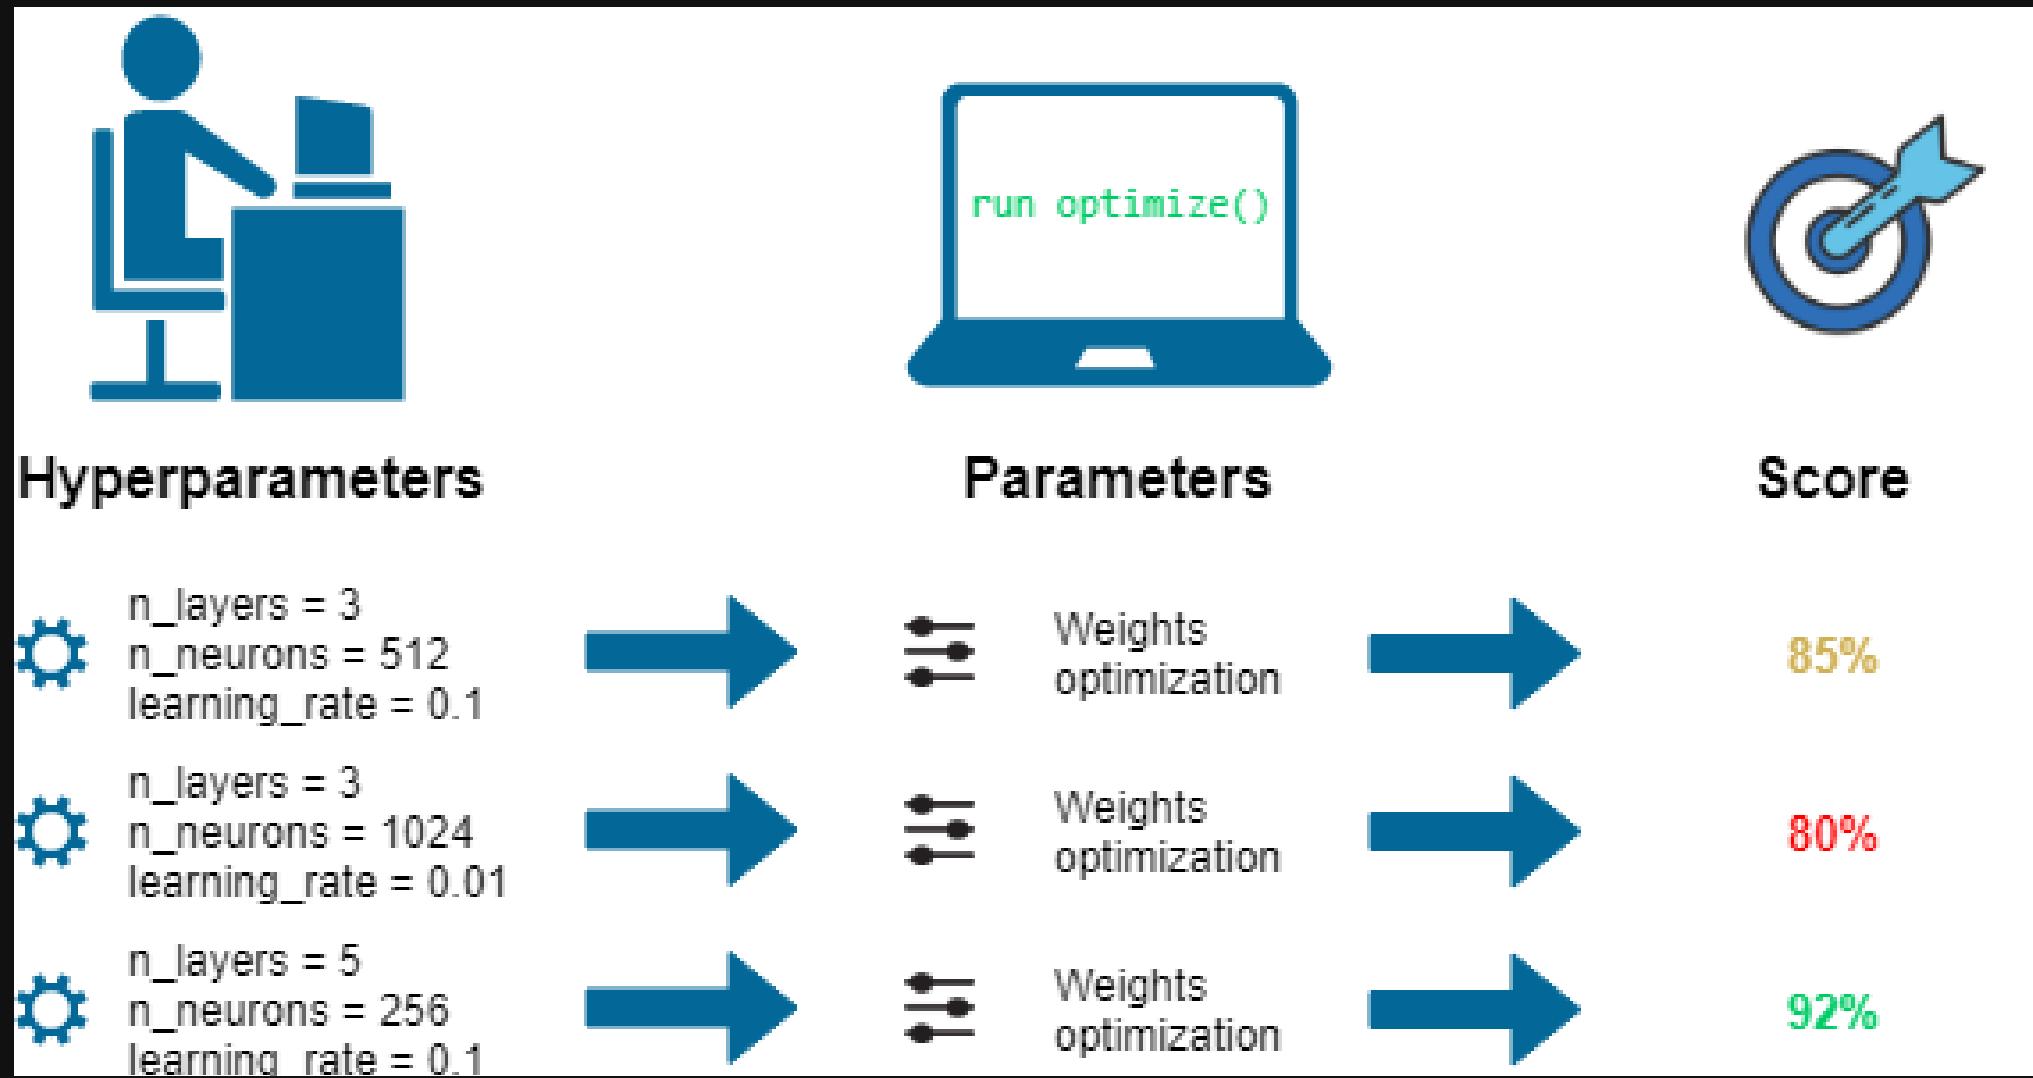
```
1 class MLP_var(nn.Module):
2     def __init__(self, N_layer: int):
3         super(MLP_var, self).__init__()
4         layers = [ ]
5         layers.append(nn.Linear(28*28, 64))
6         layers.append(nn.ReLU())
7         for _ in range(N_layer-1):
8             layers.append(nn.Linear(64, 64))
9             layers.append(nn.ReLU())
10        layers.append(nn.Linear(64, 10))
11        self.model = nn.Sequential(*layers)
12
13    def forward(self, x):
14        x = x.view(x.size(0), -1)
15        x = self.model(x)
16        return x
```

Hyperparameter Search



Hyperparameter Search

Try different Values, pick best score





Hyperparameters

	run optimize()
	Parameters
	Score
	n_layers = 3 n_neurons = 512 learning_rate = 0.1



Parameters

Score

85%

Weights optimization

Weights optimization

80%

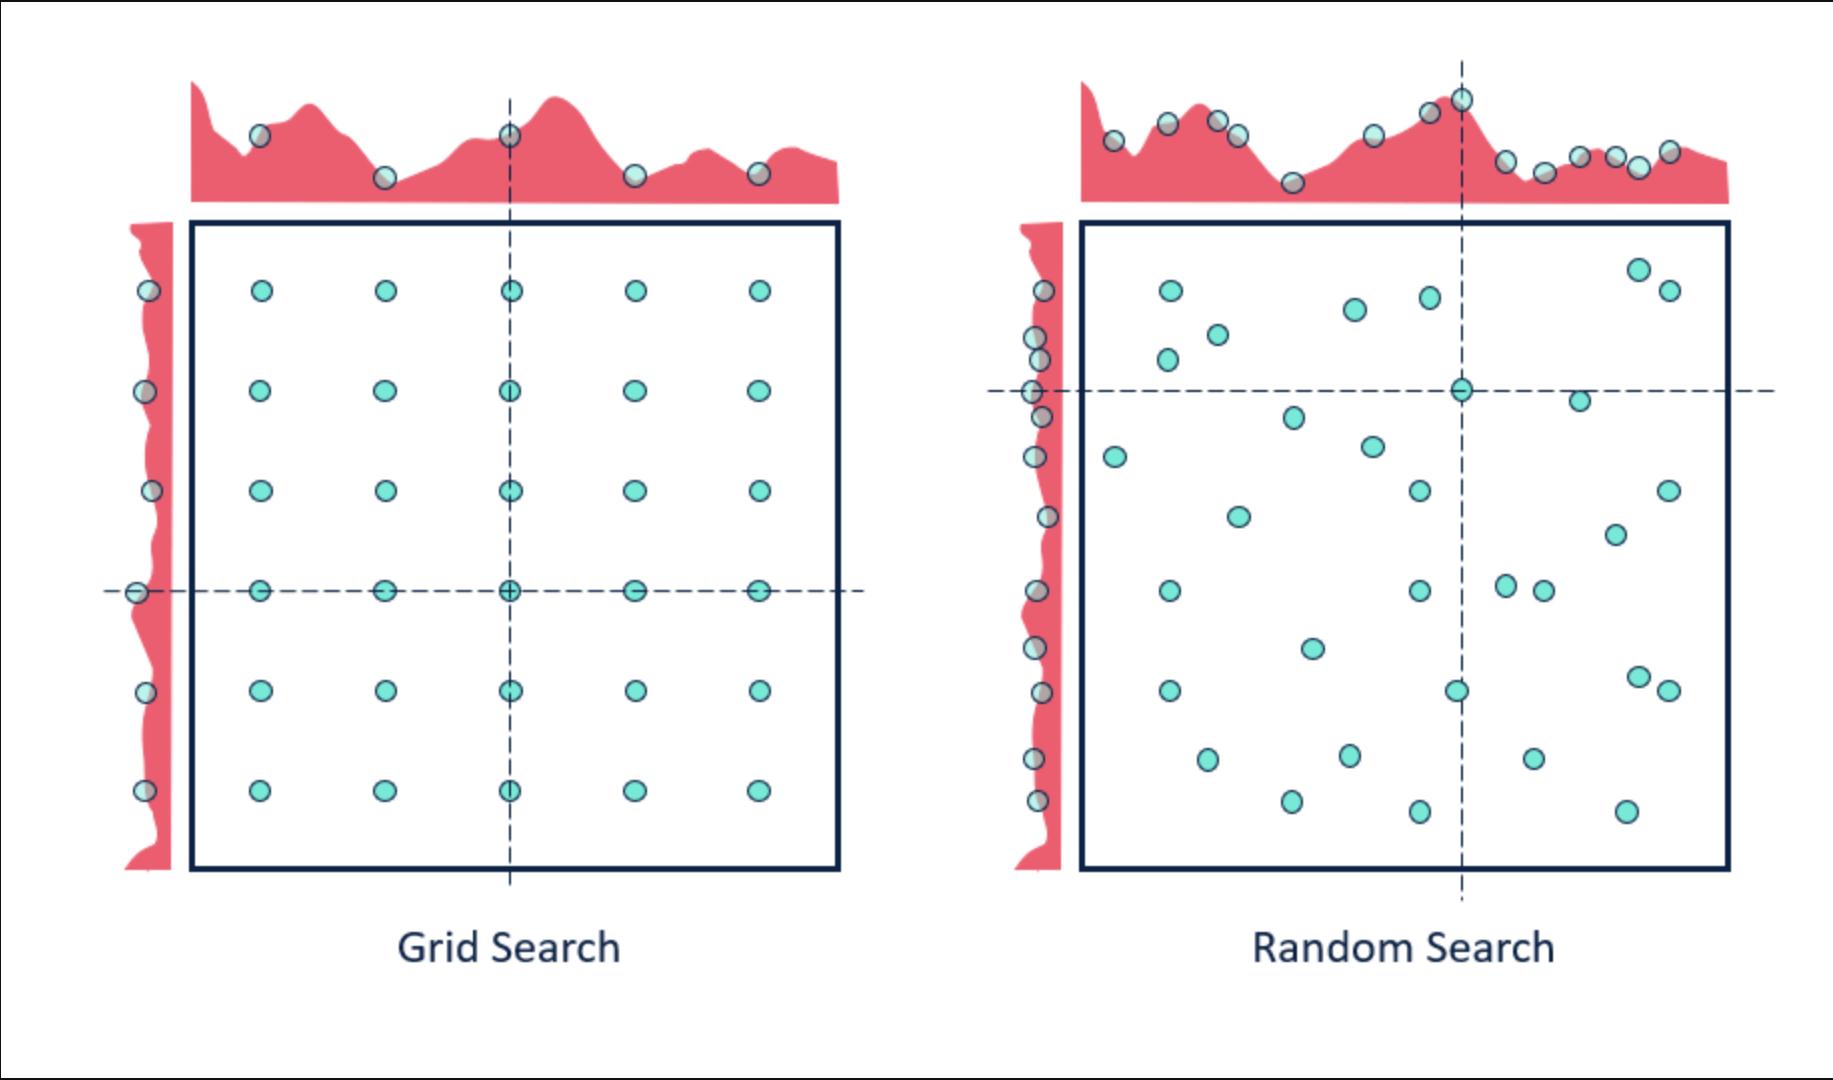
Weights optimization

92%

Weights optimization

Hyperparameter Search

Try different Values, pick best score



Grid Search

Random Search



Hyperparameters

n_layers = 3
n_neurons = 512
learning_rate = 0.1n_layers = 3
n_neurons = 1024
learning_rate = 0.01n_layers = 5
n_neurons = 256
learning_rate = 0.1

Parameters



Score

Weights optimization

85%

Weights optimization

80%

Weights optimization

92%

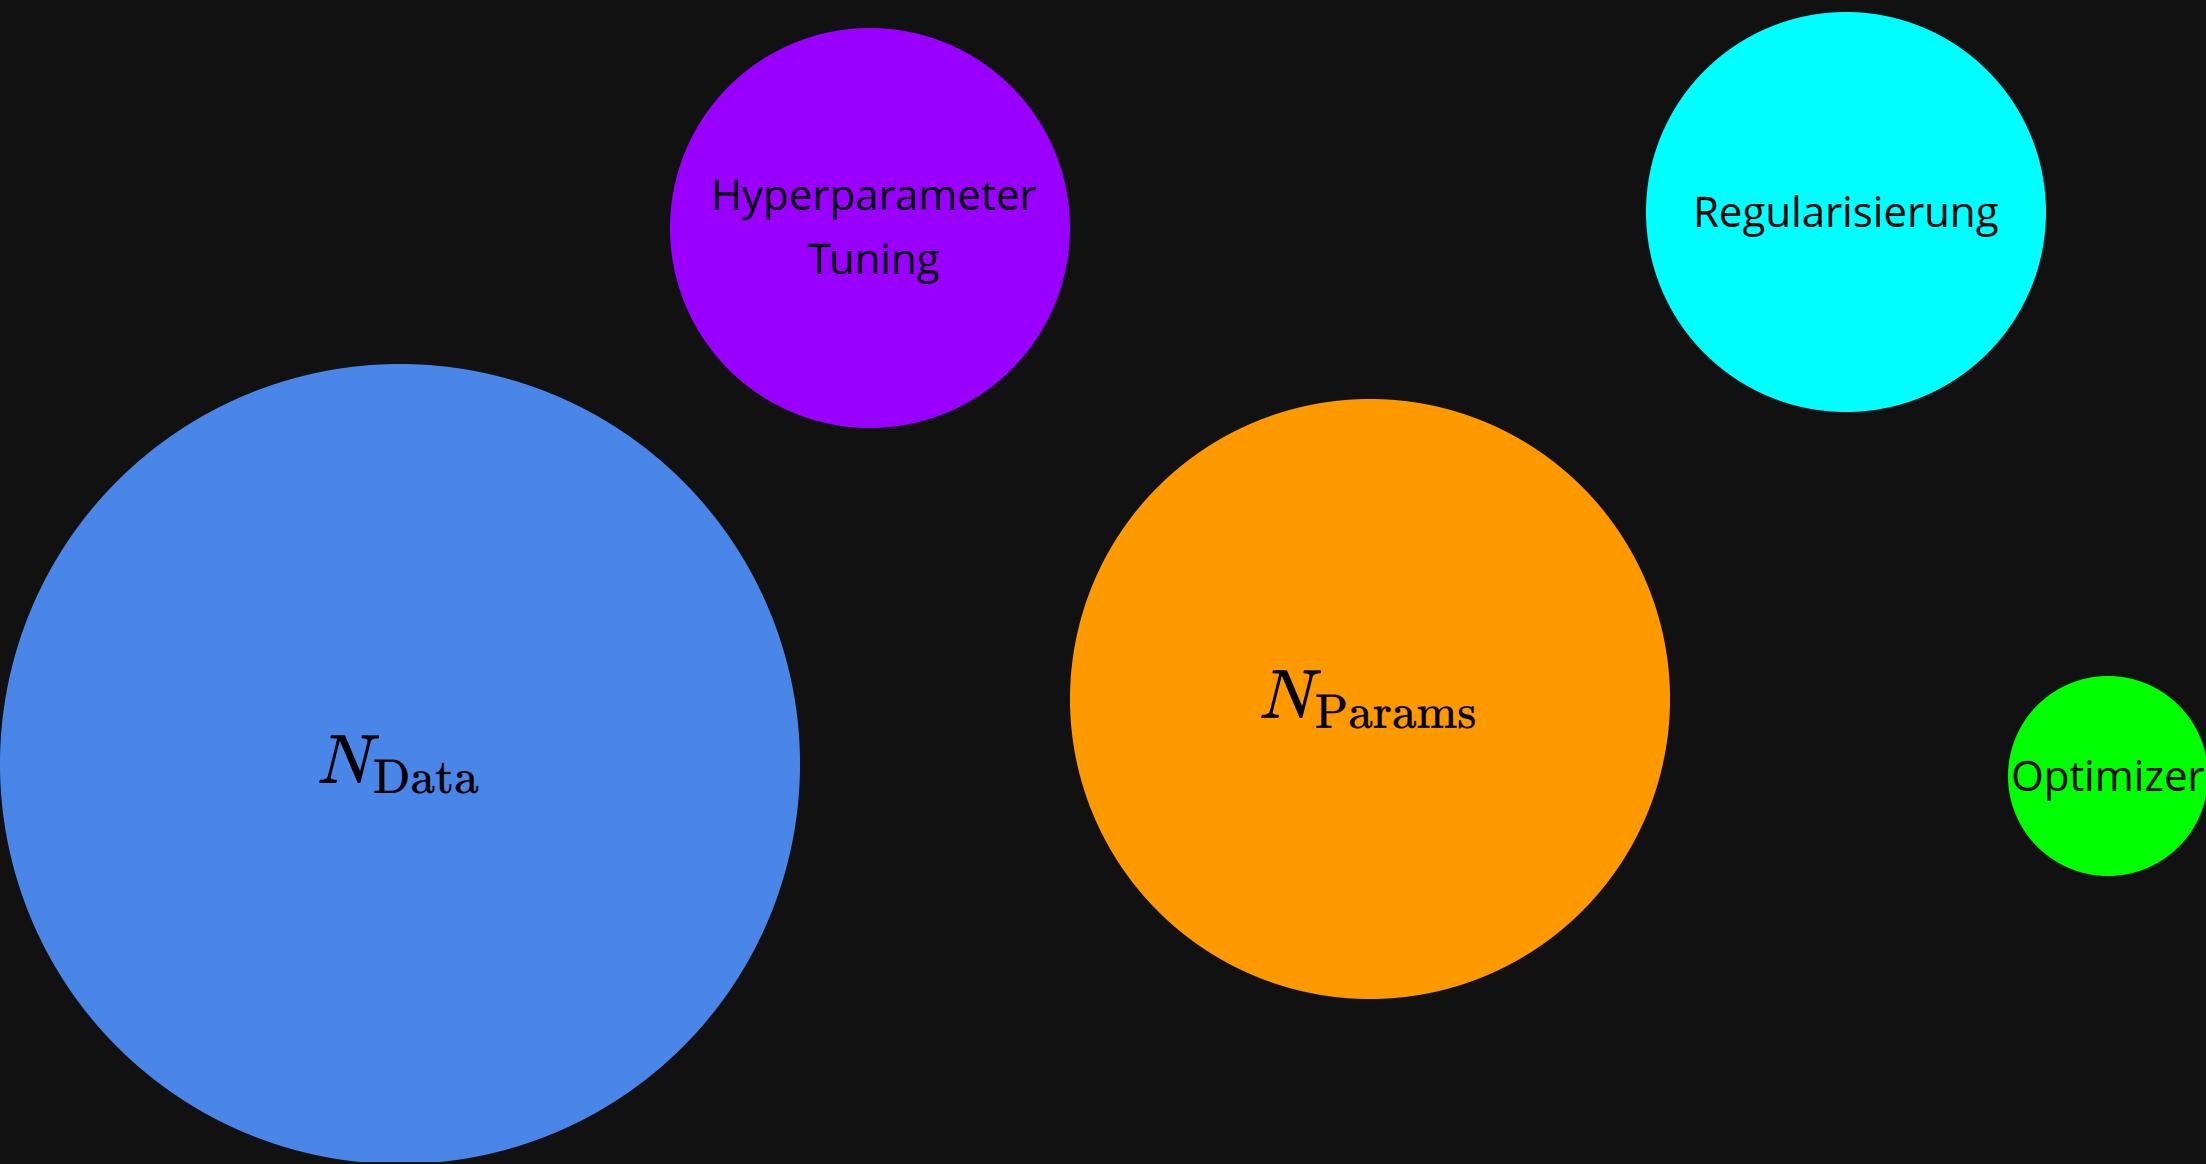
Hyperparameter Search

Gridsearch

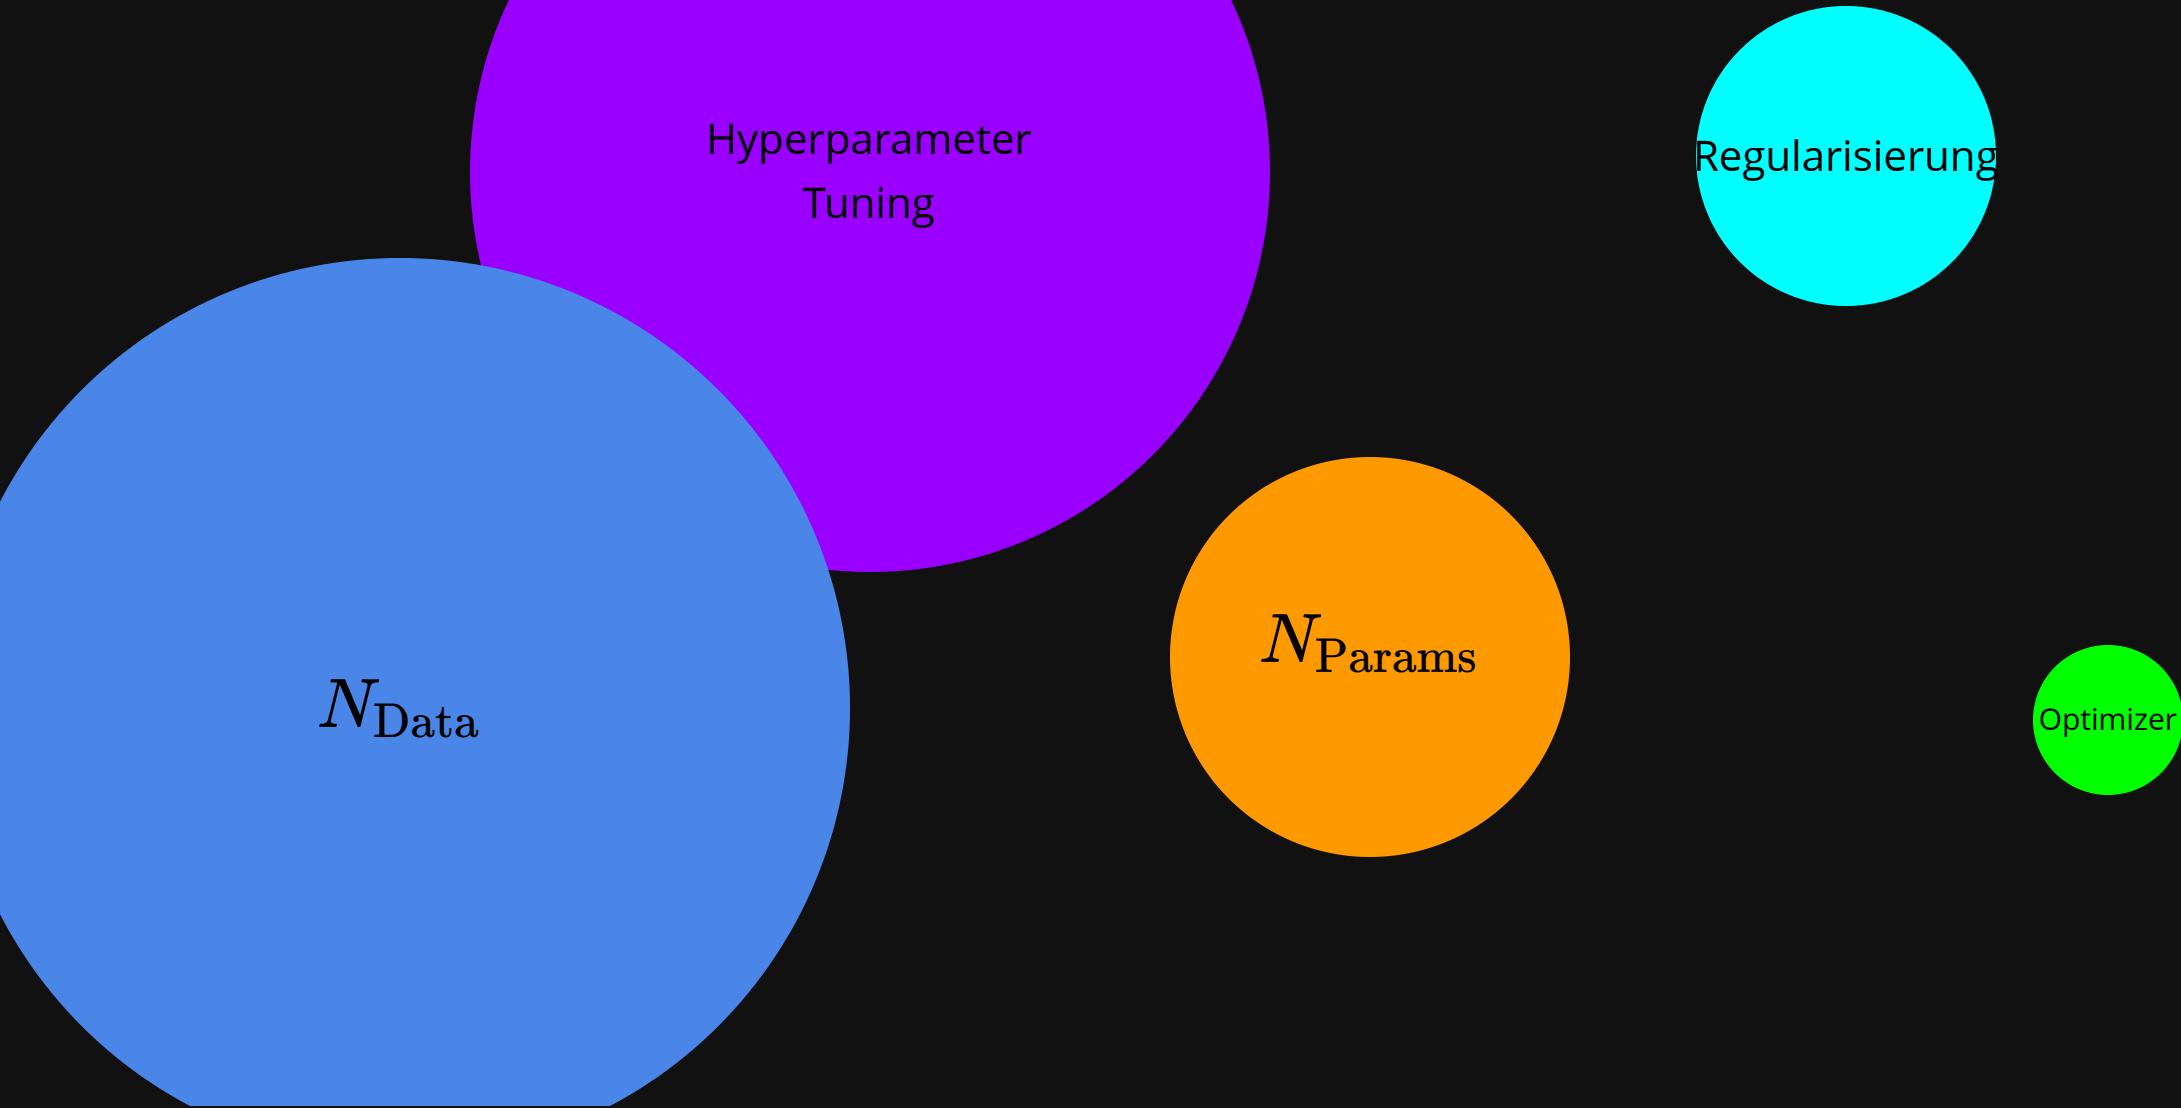


```
1 for (N_layer, lr) in product(N_layer_values, learning_rate_values):
2     model = MLP_var(N_layer)
3     model.to(device)
4     criterion = nn.CrossEntropyLoss()
5     optimizer = optim.Adam(model.parameters(), lr=lr)
6
7     losses_train, losses_valid, f1_scores_train, f1_scores_valid = full_training(
8         model, criterion, optimizer, training_loader, valid_loader, epochs=epochs
9     )
```

Einfluss auf Stabilität



Aufwand



Optimieren

Hands-On: MNIST Classifier

Bearbeiten Sie dieses Notebook

- Erstellen Sie einen MNIST Classifier mit variabler Anzahl hidden Layer
- Erstellen Sie einen Validationsdatensatz
- Führen sie ein Hyperparametertuning durch

Die Lösung finden Sie in diesem Notebook