



# Multivariate Verfahren

MSc Psychologie | MSc Klinische Psychologie und Psychotherapie

WiSe 2023/24

Prof. Dr. Dirk Ostwald

## (8) Prädiktion und Kreuzvalidierung

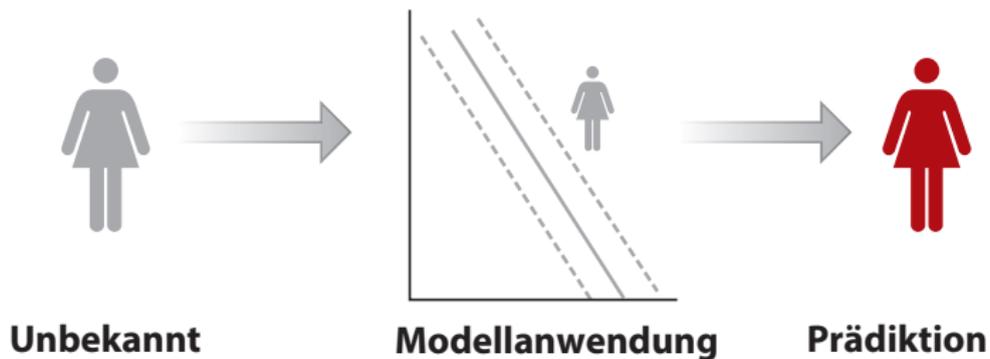
---

# Prädiktive Modellierung und Maschinelles Lernen

Kreuzvalidierung

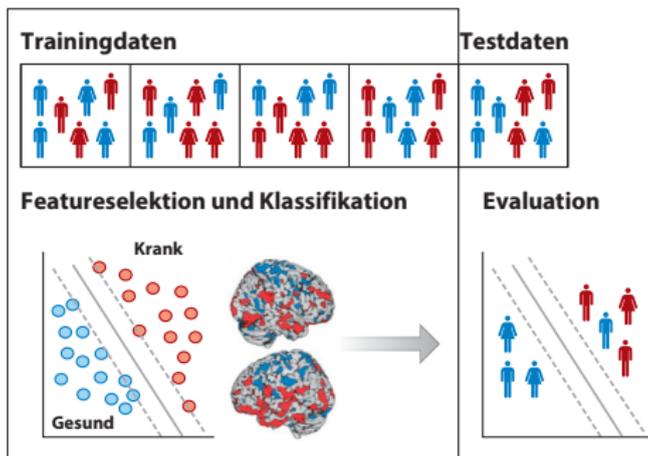
Selbstkontrollfragen

## Rhetorik der Prädiktiven Modellierung und des Maschinellen Lernens



Dwyer, Falkai, and Koutsouleris (2018)

### Modelloptimierung



Dwyer, Falkai, and Koutsouleris (2018)

Daten

Statistisches Modell

Schätzen von Parametern

Trainingsdaten und Testdaten

Modell, Machine Learning Algorithmus

Trainieren des Modells, Parameterlernen, Supervised Learning

## Definition (Binärer Klassifikationsdatensatz)

Ein *binärer Klassifikationsdatensatz*

$$\mathcal{D} := \{(x_1, y_1), \dots, (x_n, y_n)\} = \{(x_i, y_i)\}_{i=1}^n \quad (1)$$

ist eine Menge von  $n$  *Trainingsdatenpunkten*

$$(x_i, y_i) \text{ mit } x_i \in \mathbb{R}^m \text{ und } y_i \in \{0, 1\} \text{ for } i = 1, \dots, n, \quad (2)$$

wobei  $x_i$  *m-dimensionalen Featurevektor* und  $y_i$  *Label* genannt wird. Üblicherweise werden die Trainingsdatenpunkte dabei als unabhängige und identische Realisierungen eines Zufallsvektors  $m + 1$ -dimensionalen Zufallsvektors  $\zeta := (\xi, \nu)$  verstanden.

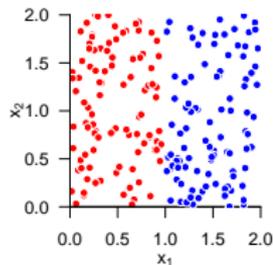
### Bemerkungen

- $y_i \in \{0, 1\}$  bezeichnet die Klassenzugehörigkeit des Featurevektors  $x_i \in \mathbb{R}^m$ .
- Ein Beispiel für  $y_i$  ist "Kein Therapieerfolg" (0) vs. "Therapieerfolg" (1).
- Beispiele für die  $m$  Komponenten der  $x_i$  sind Testscores, Biomarker, Soziodemographische Daten.

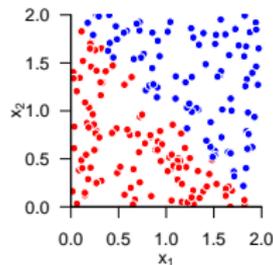
## Beispiele bivariater Featureplotszenarien

$$x_i \in \mathbb{R}^2, y_i \in \{0, 1\}, i = 1, \dots, n, \bullet y_i = 0, \bullet y_i = 1$$

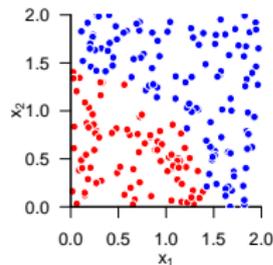
$$x_{i_1} > 1 \Leftrightarrow y_i = 1$$



$$x_{i_1} + x_{i_2} > 2 \Leftrightarrow y_i = 1$$




$$x_{i_1}^2 + x_{i_2}^2 > 2 \Leftrightarrow y_i = 1$$



## Anwendung der prädiktiven Modellierung

Explanatorische Modellierung  $\Leftrightarrow$  Grundlagenforschung

Bestimmung von  $\hat{\phi} := \operatorname{argmin} \|\hat{\phi} - \phi\|$



Bestimmung von  $\hat{f} := \operatorname{argmin}_{f \in F} \|\nu - f(\xi)\|$ ,  $F$  beliebig

Prädiktive Modellierung  $\Leftrightarrow$  Anwendungsorientierte Forschung

Shmueli (2010), Sainani (2014)

---

# Prädiktive Modellierung und Maschinelles Lernen

## **Kreuzvalidierung**

## Selbstkontrollfragen

## Workflow der prädiktiven Modellierung

### Featureselektion

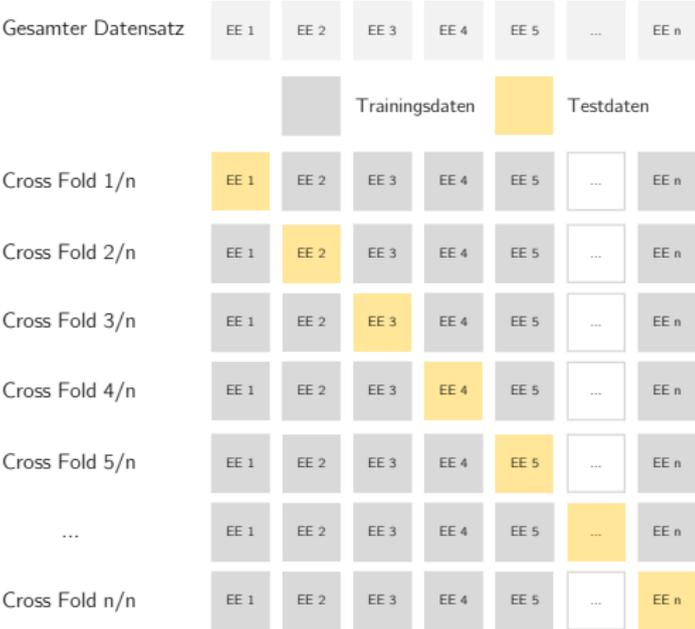
- Auswahl von möglichen prädiktiven Variablen
- Dimensionreduktion zur Verringerung des Curse of Dimensionality

### Kreuzvalidierung

- Wiederholtes Trainieren und Testen eines Modells an einem Datensatz
- Einsatz zur Modelloptimierung
- Einsatz zur Messung der probabilistischen Assoziation von Features und Labeln

# Kreuzvalidierung

## Leave-One-Out-Crossvalidation (LOOCV) bei $n$ experimentellen Einheiten (EE)



# Kreuzvalidierung

Konfusionsmatrix bei LOOCV mit binärem Label für Testendatenpunkt  $(x_i, y_i)$

		Prädiktion		
		$f(x_i) = 0$	$f(x_i) = 1$	
Fall	$y_i = 0$	Richtig Negativ $r_n$	Falsch Positiv $f_p$	Gesamt Negativ $r_n + f_p$
	$y_i = 1$	Falsch Negativ $f_n$	Richtig Positiv $r_p$	Gesamt Positiv $f_n + r_p$
		Negative Prädiktion $r_n + f_n$	Positive Prädiktion $f_p + r_p$	

Exemplarische Performanzmaße bei LOOCV mit binärem Label

- Akkuratheit (Accuracy)

$$\text{ACC} = \frac{\text{Anzahl richtiger Prädiktionen}}{\text{Anzahl aller Prädiktionen}} = \frac{r_n + r_p}{r_n + r_p + f_n + f_p} \quad (3)$$

- Sensitivität (Richtig-positiv-Rate, True Positive Rate, Recall, Hit Rate)

$$\text{SEN} = \frac{\text{Anzahl richtiger Positivprädiktionen}}{\text{Anzahl positiver Fälle}} = \frac{r_p}{f_n + r_p} \quad (4)$$

- Spezifität (Richtig-negativ-Rate, True Negative Rate, Correct Rejection Rate)

$$\text{SPE} = \frac{\text{Anzahl richtiger Negativprädiktionen}}{\text{Anzahl negativer Fälle}} = \frac{r_n}{r_n + f_p} \quad (5)$$

---

# Prädiktive Modellierung und Maschinelles Lernen

Kreuzvalidierung

**Selbstkontrollfragen**

# Selbstkontrollfragen

---

1. Erläutern Sie die Rhetorik der Prädiktiven Modellierung.
2. Geben Sie die Definition eines binären Klassifikationstrainingdatensatzes wieder.
3. Erläutern Sie Unterschiede und Gemeinsamkeiten der explanatorischen und prädiktiven Modellierung.
4. Erläutern Sie die Idee der Leave-One-Out-Crossvalidation (LOOCV).
5. Erläutern Sie die Konfusionsmatrix bei LOOCV mit binärem Label.
6. Geben Sie die Definitionen von Akkuratheit, Sensitivität und Spezifität bei LOOCV wieder.

- Dwyer, Dominic B., Peter Falkai, and Nikolaos Koutsouleris. 2018. "Machine Learning Approaches for Clinical Psychology and Psychiatry." *Annual Review of Clinical Psychology* 14 (1): 91–118. <https://doi.org/10.1146/annurev-clinpsy-032816-045037>.
- Sainani, Kristin L. 2014. "Explanatory Versus Predictive Modeling." *PM&R* 6 (9): 841–44. <https://doi.org/10.1016/j.pmrj.2014.08.941>.
- Shmueli, Galit. 2010. "To Explain or to Predict?" *Statistical Science* 25 (3). <https://doi.org/10.1214/10-STS330>.