

# Planen and Evaluieren von Machine Learning Experimenten

Marina Sedinkina  
Folien von Benjamin Roth

CIS LMU München

# Übersicht

- 1 Entwickeln von maschinellen Lernverfahren
  - Verbessern eines machine-learning Algorithmus
  - Aufteilung der Daten
  - Hyperparameter Optimization
  - Underfitting und Overfitting Erkennen
  - Datenmenge und Learning Curves
- 2 Zusammenfassung und praktische Tipps

# Übersicht

- 1 Entwickeln von maschinellen Lernverfahren
  - Verbessern eines machine-learning Algorithmus
  - Aufteilung der Daten
  - Hyperparameter Optimization
  - Underfitting und Overfitting Erkennen
  - Datenmenge und Learning Curves
- 2 Zusammenfassung und praktische Tipps

# Übersicht

- 1 Entwickeln von maschinellen Lernverfahren
  - Verbessern eines machine-learning Algorithmus
  - Aufteilung der Daten
  - Hyperparameter Optimization
  - Underfitting und Overfitting Erkennen
  - Datenmenge und Learning Curves
- 2 Zusammenfassung und praktische Tipps

# Verbessern eines machine-learning Algorithmus

- Welches Verfahren / Setup sollte man als erstes implementieren?
- Was könnte man versuchen, um davon ausgehend bessere Ergebnisse zu erzielen?

# Verbessern eines machine-learning Algorithmus

- Welches Verfahren / Setup sollte man als erstes implementieren?
  - ▶ So einfach wie möglich.
  - ▶ Wenige Annahmen.
  - ▶ Schnell zu implementieren.
- Was könnte man versuchen, um davon ausgehend bessere Ergebnisse zu erzielen?
  - ▶ Mehr Daten
  - ▶ Weniger Features (Mindestvorkommen)
  - ▶ Zusätzliche Features
  - ▶ Andere Repräsentation der Features (Featurekombinationen, ...)
  - ▶ Mehr/Weniger Regularisierung, andere Hyperparameter

# Verbessern eines machine-learning Algorithmus

- Klassifizierung von Email Spam:  
Angenommen, es wurde ein Klassifikator (SVM) auf den Trainingsdaten trainiert
- Auf einem neuen Datensatz ergibt sich eine hohe Fehlerquote.
- Was sollte als nächstes ausprobiert werden?
  - ▶ Mehr Daten
  - ▶ Weniger Features (Mindestwortfrequenz)
  - ▶ Zusätzliche Features (linguistische Analyse)
  - ▶ Andere Repräsentation der Features (Featurekombinationen, ...)
  - ▶ Mehr/Weniger Regularisierung, andere Hyperparameter

# Verbessern eines machine-learning Algorithmus

- Klassifizierung von Email Spam:  
Angenommen, es wurde ein Klassifikator (SVM) auf den Trainingsdaten trainiert
- Auf einem neuen Datensatz ergibt sich eine hohe Fehlerquote.
- Was sollte als nächstes ausprobiert werden?
  - ▶ Mehr Daten
  - ▶ Weniger Features (Mindestwortfrequenz)
  - ▶ Zusätzliche Features (linguistische Analyse)
  - ▶ Andere Repräsentation der Features (Featurekombinationen, ...)
  - ▶ Mehr/Weniger Regularisierung, andere Hyperparameter
- Manche dieser Optionen sind für sich genommen bereits ein umfangreiches Projekt.
- Die Frage wie weiter vorgegangen wird, sollte systematisch entschieden werden! (nicht intuitiv!)

# Fehlerdiagnostik

- Diagnostik: Verfahren um herauszufinden, was funktionieren könnte, und was nicht.
- Orientierungshilfe, wie die Vorhersagequalität eines machine learning-Algorithmus' verbessert werden könnte.
- Die Implementierung einer Fehlerdiagnostik nimmt Zeit in Anspruch.

# Performanz-Maße

- Ein Performanz-Maß ermöglicht die Vorhersagequalität eines Algorithmus quantitativ festzustellen
- Welches Maß verwendet werden kann, hängt von der Art der Aufgabe ab:
  - ▶ Klassifikation: Accuracy, F1-Score
  - ▶ Ranking: Mean Average Precision
  - ▶ Regression: Mean Squared Error
  - ▶ Spezialmaße: BLEU, ...

# Übersicht

- 1 **Entwickeln von maschinellen Lernverfahren**
  - Verbessern eines machine-learning Algorithmus
  - **Aufteilung der Daten**
  - Hyperparameter Optimization
  - Underfitting und Overfitting Erkennen
  - Datenmenge und Learning Curves
  
- 2 **Zusammenfassung und praktische Tipps**

# Aufteilung der Daten

- Erster Ansatz: Daten in Trainings und Testdatensatz aufteilen.

Email Betreff	Label
y 2 k - texas log	1
emerging small cap	0
re : patches work better than pillz	0
meter 1431 - nov 1999	1
re : lyondell citgo	1
dobmeos with high my energy level has gone up	0
re : entex transision	1
your prescription is ready . . oxwq s f e	0
get that new car 8434	0
entex transision	1
unify close schedule	1
await your response	0

# Auswahl eines Modells

- Folgende Modelle werden durchprobiert:
  - ▶ 100 Merkmale
  - ▶ 1000 Merkmale
  - ▶ 10000 Merkmale
  - ▶ ...
- Option 1: Optimierte Parameter für jedes der Modelle (anhand Trainingsset), und wähle Modell anhand des Performanz-Maßes auf dem Test-set.
- Angenommen das Modell mit 1000 Merkmalen gibt das beste Ergebnis.
- Ist das Performanz-Maß auf den Testdaten eine korrekte Schätzung der in Zukunft zu erwartenden Performanz?

# Auswahl eines Modells

- Folgende Modelle werden durchprobiert:
  - ▶ 100 Merkmale
  - ▶ 1000 Merkmale
  - ▶ 10000 Merkmale
  - ▶ ...
- Option 1: Optimierte Parameter für jedes der Modelle (anhand Trainingsset), und wähle Modell anhand des Performanz-Maßes auf dem Test-set.
- Angenommen das Modell mit 1000 Merkmalen gibt das beste Ergebnis.
- Ist das Performanz-Maß auf den Testdaten eine korrekte Schätzung der in Zukunft zu erwartenden Performanz?
- Antwort: Nein. Der zusätzliche Parameter "Anzahl der Merkmale" ist auf das Testset überangepasst.

# Auswahl eines Modells

- Besser: Daten in Trainings-, Kreuzvalidierungs- and Testdaten aufteilen (z.B. 60%–20%–20%).
- Kreuzvalidierungsdaten werden auch Entwicklungsdaten genannt (cross-validation set, development set).

Subject	Label
y 2 k - texas log	1
emerging small cap	0
re : patches work better then pillz	0
meter 1431 - nov 1999	1
re : lyondell citgo	1
dobmeos with hgh my energy level has gone up	0
re : entex transision	1
your prescription is ready . . oxwq s f e	0
get that new car 8434	0
entex transision	1
unify close schedule	1
await your response	0

# Trainings- / Kreuzvalidierungs- / Test-Fehler

- Merkmalsgewichte werden auf Trainingsdaten geschätzt.
- Das Modell (Merkmale, Hyperparameter) wird anhand der Kreuzvalidierungsdaten ausgewählt.
- Die zu erwartende Performanz des Modells wird anhand der Testdaten ermittelt.
- Ergebnisse auf Trainings- oder Kreuzvalidierungsdaten können nicht als Bewertung des Algorithmus aufgefasst werden!


# Übersicht

- 1 **Entwickeln von maschinellen Lernverfahren**
  - Verbessern eines machine-learning Algorithmus
  - Aufteilung der Daten
  - **Hyperparameter Optimization**
  - Underfitting und Overfitting Erkennen
  - Datenmenge und Learning Curves
  
- 2 **Zusammenfassung und praktische Tipps**


# Hyperparameter Optimization

- Richtige Hyperparameter auszuwählen ist ein Teil des Modelltrainings!
- Viele Hyperparameter:
  - ▶  $\text{embedding\_size} \in \{10, \dots, 1000\}$
  - ▶  $\text{hidden\_size} \in \{10, \dots, 1000\}$
  - ▶  $\text{l1\_regularizer} \in \{10, \dots, 1000\}$
  - ▶  $\text{l2\_regularizer} \in \{10, \dots, 1000\}$
  - ▶  $\text{dropout} \in \{10, \dots, 1000\}$
  - ▶  $\text{optimizer} \in \{\text{rmsprop}, \text{adagrad}, \text{sgd}\}$
  - ▶ ...
  - ▶  $\text{window size} \in \{1, 2, 3\}$
- Ansatz 1: Grid-Suche, geschachtelte for-Schleife: Probiere alle möglichen Wertekombinationen aus und wähle die beste Kombination anhand des Validierungsdatensatzes aus.
- Problem: der Suchraum über alle mögliche Kombinationen wird zu groß

# Beispiel für English: Hyperparameter Optimization



# Beispiel für Deutsch: Hyperparameter Optimization



## Hyperparameter Optimization 2

- Ansatz 2, Sampling: Für jeden der verschiedenen Parameter wähle Werte aus und führe so viele Konfigurationen aus, wie du dir leisten kannst (z. B. 100). Wähle Model anhand des Performanz-Maßes auf dem Entwicklungset aus.

## Hyperparameter Optimization 2

- Ansatz 2, Sampling: Für jeden der verschiedenen Parameter wähle Werte aus und führe so viele Konfigurationen aus, wie du dir leisten kannst (z. B. 100). Wähle Model anhand des Performanz-Maßes auf dem Entwicklungset aus.
- Intuition:

# Hyperparameter Optimization 2

- Ansatz 2, Sampling: Für jeden der verschiedenen Parameter wähle Werte aus und führe so viele Konfigurationen aus, wie du dir leisten kannst (z. B. 100). Wähle Model anhand des Performanz-Maßes auf dem Entwicklungset aus.
- Intuition:
  - ▶ Einige Parameter sind unabhängig von den anderen Parameter. Es ist wichtiger, gute Werte für diese Parameter auszuwählen, als alle Kombinationen auszuprobieren.

# Hyperparameter Optimization 2

- Ansatz 2, Sampling: Für jeden der verschiedenen Parameter wähle Werte aus und führe so viele Konfigurationen aus, wie du dir leisten kannst (z. B. 100). Wähle Model anhand des Performanz-Maßes auf dem Entwicklungset aus.
- Intuition:
  - ▶ Einige Parameter sind unabhängig von den anderen Parameter. Es ist wichtiger, gute Werte für diese Parameter auszuwählen, als alle Kombinationen auszuprobieren.
  - ▶ Einige Parameter verbessern die Ergebnisse nur ein bisschen. Verschwende keine Zeit, diese Parameter zu untersuchen. Untersuche andere Parameter.

# Hyperparameter Optimization 2

- Ansatz 2, Sampling: Für jeden der verschiedenen Parameter wähle Werte aus und führe so viele Konfigurationen aus, wie du dir leisten kannst (z. B. 100). Wähle Model anhand des Performanz-Maßes auf dem Entwicklungset aus.
- Intuition:
  - ▶ Einige Parameter sind unabhängig von den anderen Parameter. Es ist wichtiger, gute Werte für diese Parameter auszuwählen, als alle Kombinationen auszuprobieren.
  - ▶ Einige Parameter verbessern die Ergebnisse nur ein bisschen. Verschwende keine Zeit, diese Parameter zu untersuchen. Untersuche andere Parameter.
- Praktische Tipps:

# Hyperparameter Optimization 2

- Ansatz 2, Sampling: Für jeden der verschiedenen Parameter wähle Werte aus und führe so viele Konfigurationen aus, wie du dir leisten kannst (z. B. 100). Wähle Model anhand des Performanz-Maßes auf dem Entwicklungset aus.
- Intuition:
  - ▶ Einige Parameter sind unabhängig von den anderen Parameter. Es ist wichtiger, gute Werte für diese Parameter auszuwählen, als alle Kombinationen auszuprobieren.
  - ▶ Einige Parameter verbessern die Ergebnisse nur ein bisschen. Verschwende keine Zeit, diese Parameter zu untersuchen. Untersuche andere Parameter.
- Praktische Tipps:
  - ▶ E.g.: 0.01, 0.1, 1, 10, 100  
or: 0.01, 0.02, 0.1, 0.3, 1, 3, 10, 30, 100  
or: 0.01, 0.02, 0.05, 0.1, 0.2, 0.5, 1, 2, 5, 10, 20, 50, 100

# Hyperparameter Optimization 3

- Ansatz 2a: Mache Sampling nur über einen kleinen "sinnvollen" Bereich von Parameterwerten.

# Hyperparameter Optimization 3

- Ansatz 2a: Mache Sampling nur über einen kleinen "sinnvollen" Bereich von Parameterwerten.
  - ▶ Falls einige Werte an der Grenze liegen:

# Hyperparameter Optimization 3

- Ansatz 2a: Mache Sampling nur über einen kleinen "sinnvollen" Bereich von Parameterwerten.
  - ▶ Falls einige Werte an der Grenze liegen:
  - ▶ Erweitere den Bereich an diesen Grenzen manuell (Konfigurationsdatei / den Code bearbeiten) und optimiere die Parameter erneut

# Hyperparameter Optimization 3

- Ansatz 2a: Mache Sampling nur über einen kleinen "sinnvollen" Bereich von Parameterwerten.
  - ▶ Falls einige Werte an der Grenze liegen:
  - ▶ Erweitere den Bereich an diesen Grenzen manuell (Konfigurationsdatei / den Code bearbeiten) und optimiere die Parameter erneut
- Ansatz 2b: Ansatz 2a automatisieren

# Hyperparameter Optimization 3

- Ansatz 2a: Mache Sampling nur über einen kleinen "sinnvollen" Bereich von Parameterwerten.
  - ▶ Falls einige Werte an der Grenze liegen:
  - ▶ Erweitere den Bereich an diesen Grenzen manuell (Konfigurationsdatei / den Code bearbeiten) und optimiere die Parameter erneut
- Ansatz 2b: Ansatz 2a automatisieren
  - ▶ Erweitere den Teilbereich, wenn der beste Wert nach  $n$  Iterationen auf einer Grenze liegt

# Hyperparameter Optimization 3

- Ansatz 2a: Mache Sampling nur über einen kleinen "sinnvollen" Bereich von Parameterwerten.
  - ▶ Falls einige Werte an der Grenze liegen:
  - ▶ Erweitere den Bereich an diesen Grenzen manuell (Konfigurationsdatei / den Code bearbeiten) und optimiere die Parameter erneut
- Ansatz 2b: Ansatz 2a automatisieren
  - ▶ Erweitere den Teilbereich, wenn der beste Wert nach n Iterationen auf einer Grenze liegt
- Mehr Ideen: *Yoshua Bengio, "Practical recommendations for gradient-based training of deep architectures"*

# Übersicht

- 1 Entwickeln von maschinellen Lernverfahren
  - Verbessern eines machine-learning Algorithmus
  - Aufteilung der Daten
  - Hyperparameter Optimization
  - **Underfitting und Overfitting Erkennen**
  - Datenmenge und Learning Curves
  
- 2 Zusammenfassung und praktische Tipps


# Feststellen von Bias oder Variance

- Bias: Unteranpassung an Trainingsdaten (underfit).
  - ▶ Modell nicht “mächtig” genug.
  
- Variance: Überanpassung an Trainingsdaten (overfit).

# Feststellen von Bias oder Variance


- Bias: Unteranpassung an Trainingsdaten (underfit).
  - ▶ Modell nicht “mächtig” genug.
  - ▶ Zu wenige Merkmale?
  - ▶ Zu viel Regularisierung?
- Variance: Überanpassung an Trainingsdaten (overfit).
  - ▶ Zu viele Parameter/Merkmale?
  - ▶ Zu wenig Regularisierung?
  - ▶ Zu wenige Daten?

# Fehlerrate bei Erhöhen der Modellkapazität




# Diagnose: Underfitting oder Overfitting?

- Angenommen der Crossvalidierungsfehler ist groß.
- Ist es ein Bias- (underfitting) oder Variance- (overfitting) Problem?



# Diagnose: Underfitting oder Overfitting?

- Angenommen der Crossvalidierungsfehler ist groß.
- Ist es ein Bias (underfitting) oder Variance (overfitting) Problem?



# Diagnose: Underfitting oder Overfitting


- Bias (underfitting):
  - ▶ train error hoch
  - ▶ cv error  $\approx$  train error
- Variance (overfitting):
  - ▶ train error niedrig
  - ▶ cv error  $\gg$  train error

# Übersicht

- 1 Entwickeln von maschinellen Lernverfahren
  - Verbessern eines machine-learning Algorithmus
  - Aufteilung der Daten
  - Hyperparameter Optimization
  - Underfitting und Overfitting Erkennen
  - Datenmenge und Learning Curves
- 2 Zusammenfassung und praktische Tipps


# Learning Curves

- “Learning Curve”: Fehlerfunktion in Abhängigkeit von der Datenmenge.
- Je mehr Daten im Training vorhanden sind, desto schwieriger ist es ein Modell zu finden, dass alle Trainingsdaten perfekt modelliert ...




# Learning Curves

- “Learning Curve”: Fehlerfunktion in Abhängigkeit von der Datenmenge
- Je mehr Daten im Training vorhanden sind, desto schwieriger ist es ein Modell zu finden, dass alle Trainingsdaten perfekt modelliert ...
- ... jedoch steigt bei mehr Trainingsdaten die Qualität der Vorhersage für ungesehene Daten.




# Learning Curves bei underfitting-Modellen

- Bei underfitting-Modellen ändert sich der Fehler in Abhängigkeit von zusätzlichen Daten nicht wesentlich.



# Learning Curves bei overfitting-Modellen

- Großer Unterschied zwischen Trainings- und Testfehler.
- Zusätzliche Trainingsdaten reduzieren den Testfehler.
- Zusätzliche Trainingsdaten erhöhen den Trainingsfehler (weniger Overfitting)




# Übersicht

- 1 Entwickeln von maschinellen Lernverfahren
  - Verbessern eines machine-learning Algorithmus
  - Aufteilung der Daten
  - Hyperparameter Optimization
  - Underfitting und Overfitting Erkennen
  - Datenmenge und Learning Curves
- 2 Zusammenfassung und praktische Tipps

# Sind mehr Daten immer besser?

- Daten zu gewinnen ist mit Aufwand verbunden.
- Wann lohnt sich dieser Aufwand?



[Banko & Brill, 2001]

# Sind mehr Daten immer besser?

- Banko and Brill 2001: "It's not who has the best algorithm that wins. It's who has the most data."
- Annahmen:
  - ▶ Merkmale enkodieren alle wesentlichen Informationen, so dass ein Mensch die Entscheidung souverän treffen könnte.
  - ▶ Der Lernalgorithmus hat eine hohe Kapazität (hohe Varianz, overfitting).
- Unter diesen Annahmen ist es eine gute Idee, mehr Daten zu gewinnen.
- Ansonsten ist es vielversprechender, an Merkmalen und Algorithmus zu arbeiten.

# Zusammenfassung: Verbessern von Performanz

- Ausgangssituation: Klassifikator hat zu große Fehlerrate auf Kreuzvalidierungsdaten.
- Diagnostik: Learning Curves
  - ▶ Testfehler und CV-Fehler für 10%, 20%, ... 100% der Testdaten anzeigen.
  - ▶  $\Rightarrow$  Overfitting oder Underfitting.
- Nächste Schritte:
  - ▶ Problem ist Overfitting:
    - ★ Regularisierung erhöhen
    - ★ Weniger Merkmale
    - ★ Mehr Trainingsdaten
  - ▶ Problem ist Underfitting:
    - ★ Regularisierung erniedrigen
    - ★ Merkmalskombinationen
    - ★ Zusätzliche Merkmale

# Fehleranalyse

- Beginne mit einem einfachen Algorithmus, der schnell implementiert werden kann.
- Auf Kreuzvalidierungsdaten testen und Hyperparameter optimieren.
- Learning Curves anzeigen, um zu sehen ob mehr Daten oder mehr Features helfen könnten.
- Fehleranalyse:
  - ▶ Von Hand Beispiele in den Kreuzvalidierungsdaten suchen, bei denen der Algorithmus Fehler gemacht hat.
  - ▶ Gibt es systematische Fehler?
- Falls das Problem Underfitting war, neue Features anhand der Beobachtungen konstruieren.
- Falls das Problem Overfitting war, Features anhand der Beobachtungen generalisieren (oder neue Daten gewinnen).

# Fehleranalyse: Spam-Email Beispiel

- 500 Beispiele in Kreuzvalidierungsset
- 100 falsch klassifiziert
- Durchsehen und von Hand kategorisieren:
- Welche Art von Email:
  - ▶ Pharma
  - ▶ Gefälschte Produkte
  - ▶ Fishing-emails
  - ▶ andere
- Welche Features könnten helfen:
  - ▶ Länge der Email
  - ▶ Beabsichtigte Schreibfehler
  - ▶ andere

# Noch Fragen?

