

Universität Potsdam
Institut für Informatik
Lehrstuhl Maschinelles Lernen



Hypothesenbewertung

Christoph Sawade/Niels Landwehr

Silvia Makowski

Tobias Scheffer

Überblick

- Hypothesenbewertung, Risikoschätzung
- Anwendungen/Beispiele
- Konfidenzintervalle
- Roc-Analyse

Überblick

- Hypothesenbewertung, Risikoschätzung
- Anwendungen/Beispiele
- Konfidenzintervalle
- Roc-Analyse

Lernen und Vorhersage

- Klassifikation, Regression: Lernproblem
 - ◆ Eingabe: Trainingsdaten $L = \langle (\mathbf{x}_1, y_1), \dots, (\mathbf{x}_m, y_m) \rangle$
 - ◆ Ausgabe: Hypothese (Modell) $f : X \rightarrow Y$

- Modell wird verwendet, um Vorhersagen für neue Testbeispiele zu treffen

$$f(\mathbf{x}) = ? \in \mathcal{Y} \quad \mathbf{x} \in \mathcal{X} \quad \text{Testbeispiel}$$


- Verschiedene Verfahren kennengelernt
 - ◆ Lineare Modelle, Entscheidungsbäume, Naive Bayes...

Hypothesenbewertung

- Frage: Nachdem wir Verfahren implementiert, Hypothese trainiert haben etc.: wie gut sind die Vorhersagen?
 - ◆ Was genau heißt „gut“?
 - ◆ Wie berechnet / misst / schätzt man es?
- „Gute Vorhersagen“: in der Zukunft, wenn die gelernte Hypothese eingesetzt wird (auf Testdaten)
- „Hypothesenbewertung“: Abschätzung der Genauigkeit/Güte von Vorhersagen gelernter Modelle

Hypothesenbewertung

- Um Hypothesenbewertung formal zu untersuchen, müssen wir Annahmen über die Eigenschaften von Trainings- und Testdaten machen
- Zentrale Annahme: dem Lernproblem liegt eine (unbekannte) Verteilung $p(\mathbf{x}, y)$ zugrunde



- Beispiel Spam-Filterung
 - ◆ $p(\mathbf{x})$ Wahrscheinlichkeit dass wir Email \mathbf{x} sehen
 - ◆ $p(y|\mathbf{x})$ Wahrscheinlichkeit dass Mensch Email \mathbf{x} als $y \in \{\text{Spam/Ok}\}$ klassifiziert

Hypothesenbewertung

- „i.i.d.“-Annahme: Beispiele sind „independent and identically distributed“.

- ◆ Trainingsdaten werden unabhängig aus der Verteilung $p(\mathbf{x}, y)$ gezogen:

$$(\mathbf{x}_i, y_i) \sim p(\mathbf{x}, y) \quad \text{Trainingsbeispiele}$$

- ◆ Testdaten ebenfalls i.i.d. aus dieser Verteilung gezogen

$$(\mathbf{x}, y) \sim p(\mathbf{x}, y) \quad \begin{array}{l} \text{Testbeispiel} \\ \text{(Anwendung des Modells)} \end{array}$$

- ◆ Immer realistisch?

- Wir nehmen im Folgenden immer i.i.d. Daten an

Verlustfunktionen

- Wir haben Annahmen darüber gemacht, welche Instanzen (\mathbf{x}, y) auftauchen werden
- Testbeispiel (\mathbf{x}, y) , Hypothese sagt $f(\mathbf{x})$.
- Verlustfunktion definiert, wie schlecht das ist:

$\ell(y, f(\mathbf{x}))$ Verlust der Vorhersage $f(\mathbf{x})$ auf Instanz (\mathbf{x}, y)

- ◆ Nicht-negativ: $\forall y, y': \ell(y, y') \geq 0$
- ◆ Problem-spezifisch, gegeben.
- Verlustfunktionen für Klassifikation
 - ◆ Zero-one loss: $\ell(y, y') = 0$, wenn $y = y'$; 1, sonst
 - ◆ Klassenabhängige Kostenmatrix
- Verlustfunktionen für Regression
 - ◆ Squared loss: $\ell(y, y') = (y - y')^2$

Hypothesenbewertung: Risiko

- Zentraler Begriff der Hypothesenbewertung: Risiko
- Risiko einer Hypothese: erwarteter Verlust für eine neue Instanz

$(\mathbf{x}, y) \sim p(\mathbf{x}, y)$ Testbeispiel \mathbf{x} mit Label y (Zufallsvariable)

$\ell(y, f(\mathbf{x}))$ Verlust auf Testbeispiel (Zufallsvariable)

$$R(f) = E[\ell(y, f(\mathbf{x}))] = \int \ell(y, f(\mathbf{x})) p(\mathbf{x}, y) d\mathbf{x}d$$

- ◆ Für Zero-One-Loss heisst Risiko auch Fehlerrate.
 - ◆ Für Squared Loss heisst Risiko auch Mean Squared Error.
- Hauptziel der Hypothesenbewertung: Risikobestimmung
 - Nicht möglich, das Risiko exakt zu bestimmen, weil $p(\mathbf{x}, y)$ unbekannt ist → Schätzproblem

Einschub: Begriff „Schätzer“

- Wir wollen das Risiko einer Hypothese aus Daten schätzen
- Formalisierung: ein **Schätzer** ist ein Verfahren, das Beobachtungen L auf einen Schätzwert abbildet.
- Beispiel Münzwurf:
 - ◆ Beobachtung N_k, N_z : wie oft Kopf/Zahl gesehen
 - ◆ schätze Münzparameter θ (Wahrscheinlichkeit, dass Kopf fällt)
- Notation: Schätzer für (unbekannten) Wert θ wird mit $\hat{\theta}$ bezeichnet

Hypothesenbewertung: Risikoschätzung

- Risikoschätzung aus Daten
- Wenn aus $p(\mathbf{x}, y)$ gezogene Daten

$$T = \langle (\mathbf{x}_1, y_1), \dots, (\mathbf{x}_m, y_m) \rangle \quad (\mathbf{x}_i, y_i) \sim p(\mathbf{x}, y)$$

gegeben sind, kann das Risiko geschätzt werden:

$$\hat{R}(f) = \frac{1}{m} \sum_{j=1}^m \ell(y_j, f(\mathbf{x}_j)) \quad \text{"Empirisches Risiko"}$$

- Wichtig: Wo kommt T her?
 - ◆ Trainingsdaten ($T=L$)?
 - ◆ Verfügbare Daten in disjunkte L und T aufteilen.
 - ◆ Cross-Validation.

Bias eines Schätzers

- Schätzer

$$\hat{R}(f) = \frac{1}{m} \sum_{j=1}^m \ell(y_j, f(\mathbf{x}_j))$$

- Schätzer ist Zufallsvariable:

- ◆ Instanzen in T zufällig gezogen

$(\mathbf{x}_j, y_j) \sim p(\mathbf{x}, y)$ Welche (\mathbf{x}_j, y_j) werden gezogen?

- ◆ Wert des Schätzers hängt von zufällig gezogenen Instanzen ab, ist also Produkt eines Zufallsprozesses

- Schätzer hat einen Erwartungswert

- Schätzer ist erwartungstreu, genau dann wenn:

- ◆ Erwartungswert des empirischen Risikos = echtes Risiko.

Bias eines Schätzers

- Schätzer $\hat{R}(f)$ ist erwartungstreu, genau dann wenn:
 - ◆ $E[\hat{R}(f)] = R(f)$
- Ansonsten hat $\hat{R}(f)$ einen Bias:
 - ◆ $Bias = E[\hat{R}(f)] - R(f)$
- Schätzer ist optimistisch, wenn
 - ◆ $Bias < 0$.
- Schätzer ist pessimistisch, wenn
 - ◆ $Bias > 0$.
- Schätzer ist erwartungstreu, wenn
 - ◆ $Bias = 0$.


Varianz eines Schätzers

- Schätzer $\hat{R}(f)$ hat eine Varianz

$$Va [\hat{R}(f)] = E[\hat{R}(f)^2] - E[\hat{R}(f)]^2$$

- Je größer die Stichprobe ist, die zum Schätzen verwendet wird, desto geringer ist die Varianz.
- Varianz vs. Bias:
 - ◆ Hohe Varianz: großer „Zufallsanteil“ bei der Bestimmung des empirischen Risikos.
 - ◆ Großer Bias: systematischer Fehler bei der Bestimmung des empirischen Risikos.

Varianz eines Schätzers



- Erwarteter (quadratischer) Fehler des Schätzers:

$$E[(\hat{R}(f) - R)^2]$$

- Lässt sich zerlegen in Bias und Varianz

$$\begin{aligned}
 E[(\hat{R}(f) - R)^2] &= E[\hat{R}(f)^2 - 2R\hat{R}(f) + R^2] \\
 &= E[\hat{R}(f)^2] - 2RE[\hat{R}(f)] + R^2 \\
 &= E[\hat{R}(f)^2] - 2RE[\hat{R}(f)] + R^2 + E[\hat{R}(f)^2] - E[\hat{R}(f)]^2 \\
 &= (E[\hat{R}(f)] - R)^2 + \text{Var}[\hat{R}(f)] \\
 &= \text{Bias}[\hat{R}(f)]^2 + \text{Var}[\hat{R}(f)]
 \end{aligned}$$

Verschiebungssatz

Risikoschätzer auf den Trainingsdaten

- Welche Menge T verwenden?
- 1. Versuch: Trainingsdaten L
- Hypothese f , trainiert auf $L = \langle (\mathbf{x}_1, y_1), \dots, (\mathbf{x}_m, y_m) \rangle$
- Empirisches Risiko gemessen auf Trainingsdaten

$$\hat{R}_L(f) = \frac{1}{m} \sum_{j=1}^m \ell(y_j, f(\mathbf{x}_j))$$

- Ist dieses empirische Risiko ein
 - ◆ erwartungstreu
 - ◆ optimistischer
 - ◆ pessimistischer
- Schätzer für das echte Risiko und warum?

Risikoschätzer auf den Trainingsdaten

- Empirisches Risiko auf den Trainingsdaten ist ein optimistischer Schätzer des echten Risikos
- Empirisches Risiko *aller möglichen* Hypothesen für ein festes L ?
 - ◆ Aufgrund von Zufallseffekten gilt für einige Hypothesen f , dass $\hat{R}_L(f) < R(f)$ und für andere Hypothesen f , dass $\hat{R}_L(f) > R(f)$.
 - ◆ Lernalgorithmus wählt eine Hypothese f_L mit kleinem empirischen Risiko $\hat{R}_L(f_L)$
 - ◆ Wahrscheinlich, dass $\hat{R}_L(f_L) < R(f_L)$ (Risiko unterschätzt)

Risikoschätzer auf den Trainingsdaten


- Empirisches Risiko der vom Lerner gewählten Hypothese auf den Trainingsdaten („Trainingsfehler“) ist ein optimistischer Schätzer des echten Risikos:

$$E[\hat{R}_L(f_L)] < R(f_L)$$

- Problem ist die Abhängigkeit von gewählter Hypothese und zur Fehlerschätzung verwendeten Daten
- Ansatz: Testdaten verwenden, die von den Trainingsdaten unabhängig sind.


Holdout-Testing

- Idee: Fehlerschätzung auf unabhängigen Testdaten
- Gegeben: Daten $D = \langle (\mathbf{x}_1, y_1), \dots, (\mathbf{x}_d, y_d) \rangle$
- Teile Daten auf in
 - ◆ Trainingsdaten $L = \langle (\mathbf{x}_1, y_1), \dots, (\mathbf{x}_m, y_m) \rangle$ und
 - ◆ Testdaten $T = \langle (\mathbf{x}_{m+1}, y_{m+1}), \dots, (\mathbf{x}_d, y_d) \rangle$



Holdout-Testing

- Starte Lernalgorithmus mit Daten L , gewinne so Hypothese f_L .
- Ermittle empirisches Risiko $\hat{R}_T(f_L)$ auf Daten T .
- Starte Lernalgorithmus auf Daten D , gewinne so Hypothese f_D .
- Ausgabe: Hypothese f_D , benutze $\hat{R}_T(f_L)$ als Schätzer für das Risiko von f_D



Holdout-Testing: Analyse

- Ist der Schätzer $\hat{R}_T(f_L)$ für Risiko der Hypothese f_D
 - ◆ erwartungstreu,
 - ◆ optimistisch,
 - ◆ pessimistisch?

Holdout-Testing: Analyse

- Schätzer $\hat{R}_T(f_L)$ ist pessimistisch für $R(f_D)$:
 - ◆ $\hat{R}_T(f_L)$ ist erwartungstreu für f_L
 - ◆ f_L wurde mit weniger Trainingsdaten gelernt als f_D und hat daher im Erwartungswert ein höheres Risiko

- Aber Schätzer $\hat{R}_T(f_L)$ ist in der Praxis brauchbar, während $\hat{R}_L(f_L)$ meist 0 (oder nahe 0) ist.

Holdout-Testing: Analyse

- Warum wird Hypothese f_D trainiert und zurückgeliefert?
- Rückgegebene Hypothese f_D und nicht f_L , weil f_D ein geringeres Risiko hat, also besser ist.

Holdout-Testing: Analyse


- Was sind die Vorteile/Nachteile wenn Testmenge T
 - ◆ möglichst groß
 - ◆ möglichst klein

gewählt wird?

- T möglichst groß, damit Risikoschätzer $\hat{R}_T(f_L)$ geringe Varianz hat.
- T möglichst klein, damit Risikoschätzer $\hat{R}_T(f_L)$ geringen Bias hat, also nicht so stark pessimistisch ist.
- Braucht viele Daten, um gute Schätzungen zu bekommen
 - ◆ Wird praktisch nur verwendet, wenn sehr viele Daten zur Verfügung stehen.
 - ◆ Cross-Validation meist besser (siehe unten)

Cross-Validation

- Gegeben: Daten $D = \langle (\mathbf{x}_1, y_1), \dots, (\mathbf{x}_d, y_d) \rangle$
- Teile D in n gleich große Abschnitte D_1, \dots, D_n mit $D = \bigcup_{i=1}^n D_i$ und $D_i \cap D_j = \emptyset$
- Wiederhole für $i=1..n$
 - ◆ Trainiere f_i mit $L_i = D \setminus D_i$
 - ◆ Bestimme empirisches Risiko $\hat{R}_{D_i}(f_i)$ auf D_i




Cross-Validation

- Middle empirische Risikoschätzungen auf den jeweiligen Testmengen D_i :


$$\bar{R} = \frac{1}{n} \sum_{i=1}^n \hat{R}_{D_i}(f_i)$$

- Trainiere f_D auf allen Daten D .
- Liefere Hypothese f_D und Schätzer \bar{R} .



Leave-One-Out Cross-Validation

- Spezialfall $n=d$ heisst auch *leave-one-out* Fehlerschätzung




Cross-Validation: Analyse

- Ist der Schätzer
 - ◆ Optimistisch / pessimistisch / erwartungstreu?


Cross-Validation: Analyse

- Ist der Schätzer
 - ◆ Optimistisch / pessimistisch / erwartungstreu?
- Schätzer ist pessimistisch:
 - ◆ Hypothesen f_i werden auf Anteil $(n-1)/n$ der verfügbaren Daten trainiert.
 - ◆ Hypothese f_D wird auf den gesamten Daten trainiert

Cross-Validation




Holdout




Cross-Validation: Analyse

- Bias/Varianz im Vergleich zu Holdout-Testing?
- Varianz ist geringer als beim Holdout-Testing
 - ◆ Mittelung über mehrere Holdout-Experimente, das reduziert die Varianz
 - ◆ Alle Daten fließen in den Schätzer ein
- Bias ähnlich wie beim Holdout-Testing, je nach Split-Verhältnissen.

Cross-Validation



Holdout



Überblick

- Hypothesenbewertung, Risikoschätzung
- **Anwendungen/Beispiele**
- Konfidenzintervalle
- Roc-Analyse

Anwendungen/Beispiele

Hypothesenevaluierung

- Wir wollen/müssen aus Anwendungsgründen wissen, wie gut Hypothese ist
 - ◆ Macht es überhaupt Sinn, maschinelles Lernen in der Anwendung zu verwenden?
 - ◆ Mit wie vielen falschen Vorhersagen müssen wir rechnen?
- Wir wollen mehrere verschiedene Lernansätze vergleichen
 - ◆ Sollte man Entscheidungsbäume verwenden?
 - ◆ SVMs?
 - ◆ Logistische Regression?
 - ◆ Naive Bayes?

Anwendungen Hypothesenevaluierung

- Verfahren hat einen Parameter, den wir einstellen müssen
 - ◆ Regularisierungsparameter λ

$$f_{\mathbf{w}_*} = \arg \min_{f_{\mathbf{w}}} \sum_i \ell(f_{\mathbf{w}}(\mathbf{x}_i), y_i) + \lambda \|\mathbf{w}\|^2 \quad \lambda=?$$

- ◆ (Hyper)Parameter, der Modellklasse bestimmt, z.B. Polynomgrad bei polynomieller Regression

$$f_{\mathbf{w}}(x) = \sum_{i=0}^M w_i x^i \quad M=?$$

- In allen diesen Fällen ist der Trainingsfehler kein geeignetes Entscheidungskriterium!
 - ◆ Fehlerschätzung mit Holdout-Menge oder Cross-Validation


Beispiel: Polynomgrad bei polynomieller Regression

- Polynommodell vom Grad M : $f_{\mathbf{w}}(x) = \sum_{i=0}^M w_i x^i$
- Wir lernen Modell durch Minimierung des quadratischen Verlustes (unregularisiert – schlecht)

$$\mathbf{w}_* = \arg \min_{\mathbf{w}} \sum_{i=1}^m (f_{\mathbf{w}}(x_i) - y_i)^2$$





Trainingsdaten

$$L = \langle (x_1, y_1), \dots, (x_m, y_m) \rangle$$




Beispiel polynomielle Regression: Training vs. Testfehler

- Erfolg des Lernens hängt vom gewählten Polynomgrad M ab, der Komplexität des Modells kontrolliert



Beispiel polynomielle Regression: Training vs. Testfehler



- Trainingsfehler vs. Testfehler für unterschiedliche Polynomgrade
 - ◆ Testfehler z.B. mit grosser Holdout-Menge gemessen



Phänomen der Überanpassung („Overfitting“):
Trainingsfehler sinkt monoton mit M , aber Testfehler steigt für große M wieder

Beispiel polynomielle Regression: Training vs. Testfehler

- Problem der Überanpassung (Overfitting) wird geringer, wenn mehr Daten verfügbar



- In der Praxis verfügbare Daten begrenzt
 - ◆ Modell muss regularisiert werden


Regularisierte Polynomielle Regression

- Polynommodell vom Grad $M=9$: $f(x) = \sum_{i=0}^M w_i x^i$
- Lerne Modell durch Minimierung des regularisierten quadratischen Verlustes

$$\mathbf{w}_* = \arg \min_{\mathbf{w}} \sum_{i=1}^M (f_{\mathbf{w}}(x_i) - y_i)^2 + \lambda \|\mathbf{w}\|^2$$

Trainingsdaten
 $L = \langle (x_1, y_1), \dots, (x_m, y_m) \rangle$

$$M = 9, \quad \ln \lambda = -18$$




Regularisierte Polynomielle Regression

- Jetzt müssen wir λ einstellen
- Regularisierungsparameter kontrolliert Komplexität ähnlich wie Polynomgrad M


$$M = 9$$

$$\ln \lambda = -\infty$$




$$M = 9$$

$$\ln \lambda = -18$$




$$M = 9$$

$$\ln \lambda = 0$$



Regularisierte Polynomielle Regression

- Trainingsfehler vs. Testfehler für unterschiedliche Werte des Regularisierungsparameters λ
 - ◆ Testfehler z.B. mit grosser Holdout-Menge gemessen





Trainingsfehler minimal ohne Regularisierung, aber Testfehler besser für regularisiertes Modell

Umgekehrtes Verhalten wie für unterschiedliche Polynomgrade

Regularisierte Polynomielle Regression

- Regularisierer wirkt wie eine Begrenzung der Modellkomplexität und verhindert Überanpassung
- In der Praxis am besten, Modellkomplexität durch Regularisierung zu kontrollieren (direkter Parameter wie bei Polynomen oft nicht verfügbar)
- Regularisierer kann durch Fehlerschätzung (Holdout-Testing oder Cross-Validation) eingestellt werden.



Triple-Cross-Validation

- Ziel: Abschätzung der Genauigkeit von Vorhersagen unter optimalen Parametern

Triple-Cross-Validation


- Gegeben: Daten $D = \langle (\mathbf{x}_1, y_1), \dots, (\mathbf{x}_d, y_d) \rangle$
- Teile D in n Abschnitte $D_i = \langle (\mathbf{x}_{i_1}, y_{i_1}), \dots, (\mathbf{x}_{i_k}, y_{i_k}) \rangle$, $k = d / n$
mit $D = \bigcup_{i=1}^n D_i$ und $D_i \cap D_j = \emptyset$
- Wiederhole für $i=1..n$
 - ◆ Teile $D \setminus D_i$ in m Abschnitte mit $D \setminus D_i = \bigcup_{j=1}^m D_{i,j}$ und $D_{i,j} \cap D_{i,k} = \emptyset$
 - ◆ Wiederhole für $j=1..m$
 - ★ Trainiere $f_{i,j,C}$ mit $D \setminus D_i \setminus D_{i,j}$ f.a. möglichen Parameter C
 - ★ Bestimme empirisches Risiko $\hat{R}_C(f_{i,j,C})$ auf $D_{i,j}$
 - ★ Bestimme C^* mit minimalen Risiko \hat{R}_C
 - ◆ Trainiere f_i mit $D \setminus D_i$ und C^*
 - ◆ Bestimme empirisches Risiko $\hat{R}_{D_i}(f_i)$ auf D_i

Triple-Cross-Validation

- Middle empirical risk estimates on the respective test sets D_i :

$$\bar{R} = \frac{1}{n} \sum_{i=1}^n \hat{R}_{D_i}(f_i)$$

- Train f_D on all data D .
- Deliver hypothesis f_D and estimator \bar{R} .




Überblick

- Hypothesenbewertung, Risikoschätzung
- Anwendungen/Beispiele
- **Konfidenzintervalle**
- Roc-Analyse

Konfidenzintervalle

- Idee Konfidenzintervall:
 - ◆ Intervall um den geschätzten Fehler $\hat{R}(f)$ angeben
 - ◆ so dass der echte Fehler „meistens“ im Intervall liegt
 - ◆ Quantifiziert Unsicherheit der Schätzung
- Weg zum Konfidenzintervall: Analyse der Verteilung der Zufallsvariable $\hat{R}(f)$

• $\hat{R}(f)$



Zero-One Loss und Fehlerwahrscheinlichkeit

- Für Konfidenzintervalle betrachten wir Risikoschätzung im Spezialfall Klassifikation mit Zero-One Loss
- Verlustfunktion Zero-One Loss:

$$\diamond \ell(y, y') = \begin{cases} 0, & \text{wenn } y = y' \\ 1, & \text{wenn } y \neq y' \end{cases}$$

- → Risiko = Fehlerwahrscheinlichkeit.

$$\begin{aligned} \diamond R(f) &= \int \ell(y, f(\mathbf{x})) p(\mathbf{x}, y) d\mathbf{x} dy \\ &= \int [[y \neq f(\mathbf{x})]] p(\mathbf{x}, y) d\mathbf{x} dy & [[Ereignis]]: & \text{binäre Indikatorvariable} \\ &= p(y \neq f(\mathbf{x})) & & \text{für "Ereignis"} \end{aligned}$$

Verteilung für Fehlerschätzer

- Hypothese f wird auf separater Testmenge mit m unabhängigen Beispielen evaluiert:

$$\hat{R}_T(f) = \frac{1}{m} \sum_{j=1}^m \ell(y_j, f(\mathbf{x}_j)) \quad T = \langle (\mathbf{x}_1, y_1), \dots, (\mathbf{x}_m, y_m) \rangle$$

- Fehlerschätzer ist erwartungstreu, $E[\hat{R}_T(f)] = R(f)$
- Betrachten zunächst unnormalisierten Fehlerschätzer

$$m \cdot \hat{R}_T(f) = \sum_{j=1}^m \ell(y_j, f(\mathbf{x}_j))$$

- Summe über Beispielerluste $\ell(y_j, f(\mathbf{x}_j)) \in \{0,1\}$
- Beispiele unabhängig: Summe über Münzwürfe
- Münzparameter ist Fehlerwahrscheinlichkeit $R(f)$

Binomialverteilung

- Unnormalisiertes empirisches Risiko

$$m \cdot \hat{R}_T(f) = \sum_{j=1}^m \ell(y_j, f(\mathbf{x}_j))$$

ist Summe von Bernoulli-Variablen, also binomialverteilt:

$$m \hat{R}_T(f) \sim \text{Bin}(m \hat{R}_T(f) \mid m, r) \quad r = R(f)$$

- ◆ Erwartungswert $E[m \cdot \hat{R}_T(f)] = mr$
- ◆ Varianz $\text{Var}[m \cdot \hat{R}_T(f)] = m \cdot r(1 - r)$

Normalisierte Binomialverteilung

- Normalisierter Fehlerschätzer: normalisierte Binomialverteilung

- Erwartungswert des normalisierten Fehlerschätzers:

$$E\left[\hat{R}_T(f)\right] = \frac{1}{m} E\left[m\hat{R}_T(f)\right] = \frac{1}{m} mr = r$$

- Varianz des normalisierten Fehlerschätzers:

$$\text{Var}\left[\hat{R}_T(f)\right] = \frac{1}{m^2} \text{Var}\left[m\hat{R}_T(f)\right] = \frac{1}{m^2} m \cdot r(1-r) = \frac{r(1-r)}{m}$$

- Standardabweichung („Standardfehler“)




$$\sigma_{\hat{r}} = \sqrt{\frac{r(1-r)}{m}}$$

- ◆ Zufallsanteil des Schätzers, sinkt mit $\frac{1}{\sqrt{m}}$

Binomialverteilung

- Binomialverteilung für große m ähnlich Normalverteilung

$r = 0.5$



Normalverteilung

- Empirisches Risiko annähernd normalverteilt:

$$\hat{R}_T(f) \sim N\left(\hat{R}_T(f) \mid r, \sigma_{\hat{r}}^2\right) \quad [\text{approximativ, für große } m]$$

$$\sigma_{\hat{r}}^2 = \frac{r(1-r)}{m}$$

- Für die weitere Analyse betrachten wir das standardisierte Risiko, dieses ist standardnormalverteilt:

$$\frac{\hat{R}_T(f) - R(f)}{\sigma_{\hat{r}}} \sim N\left(\frac{\hat{R}_T(f) - R(f)}{\sigma_{\hat{r}}} \mid 0, 1\right) \quad [\text{approximativ, für große } m]$$

- Schätzen der Varianz des empirischen Risikos:

$$\sigma_{\hat{r}}^2 \approx s_{\hat{r}}^2 \quad s_{\hat{r}}^2 = \frac{\hat{r}(1-\hat{r})}{m-1}, \quad \hat{r} = \hat{R}_T(f)$$

Schranken für echtes Risiko

- Wir haben Verteilung des empirischen Risikos hergeleitet
- Was sagt das empirische Risiko jetzt also über das echte Risiko?
- Wir können Schranke für echtes Risiko bestimmen!

$$P\left(R(f) \leq \hat{R}_T(f) + \varepsilon\right) = P\left(R(f) - \hat{R}_T(f) \leq \varepsilon\right) = P\left(\frac{R(f) - \hat{R}_T(f)}{s_{\hat{r}}} \leq \frac{\varepsilon}{s_{\hat{r}}}\right) \approx \Phi\left(\frac{\varepsilon}{s_{\hat{r}}}\right)$$

Approximativ
standardnormalverteilt

$\Phi(z)$ kumulative Verteilungsfunktion der Standardnormalverteilung

Kumulative Verteilungsfunktion der Normalverteilung

- Sei Z standardnormalverteilte Zufallsvariable

$$Z \sim \mathcal{N}(Z | 0,1)$$

- Kumulative Verteilungsfunktion der Normalverteilung:

$$\Phi(z) = p(Z \leq z)$$

$$= \int_{-\infty}^z \mathcal{N}(x | 0,1) dx$$

$$= \int_{-\infty}^z \frac{1}{\sqrt{2\pi}} \exp(-x^2 / 2) dx$$

- Keine geschlossene Lösung, nachschlagen in Tabelle

Schranken für echtes Risiko

- Ergebnis: Einseitige Schranke für echtes Risiko, gegeben ε

$$P\left(R(f) \leq \hat{R}_T(f) + \varepsilon\right) = P\left(R(f) - \hat{R}_T(f) \leq \varepsilon\right) \approx \Phi\left(\frac{\varepsilon}{s_{\hat{r}}}\right)$$

Kann man in der Praxis bestimmen:
 $s_{\hat{r}}$ beobachtet

- Zweiseitige Schranke:

$$\begin{aligned} P\left(|R(f) - \hat{R}_T(f)| \leq \varepsilon\right) &= \dots \\ &= \dots \\ &\approx 2\Phi\left(\frac{\varepsilon}{s_{\hat{r}}}\right) - 1 \end{aligned}$$

Konfidenzintervalle

- Idee Konfidenzintervall: ε so wählen, dass Schranke mit vorgegebener Wahrscheinlichkeit von $1-\delta$ (z.B. $\delta = 0.05$) gilt.
- Einseitiges $1-\delta$ -Konfidenzintervall: Schranke ε , so dass

$$P\left(R(f) \leq \hat{R}_T(f) + \varepsilon\right) \geq 1 - \delta$$

- Zweiseitiges $1-\delta$ -Konfidenzintervall: Schranke ε , so dass

$$P\left(|R(f) - \hat{R}_T(f)| \leq \varepsilon\right) \geq 1 - \delta$$

- Bei symmetrischer Verteilung gilt immer:
 - ◆ ε zu einseitigem $1-\delta$ -Konfidenzintervall
= ε zu zweiseitigem $1-2\delta$ -Konfidenzintervall.

5% Wahrscheinlichkeit, dass $R(f) > \hat{R}_T(f) + \varepsilon$

10% Wahrscheinlichkeit, dass $R(f) > \hat{R}_T(f) + \varepsilon$ oder $R(f) < \hat{R}_T(f) - \varepsilon$ 56

Konfidenzintervalle

- Ermitteln des einseitigen $1-\delta$ -Konfidenzintervalls:


$$P\left(R(f) \leq \hat{R}_T(f) + \varepsilon\right) \geq 1 - \delta$$

$$\Leftrightarrow \Phi\left(\frac{\varepsilon}{s_{\hat{r}}}\right) \geq 1 - \delta$$

$$\Leftrightarrow \frac{\varepsilon}{s_{\hat{r}}} \geq \Phi^{-1}(1 - \delta)$$

$$\Leftrightarrow \varepsilon \geq s_{\hat{r}} \Phi^{-1}(1 - \delta)$$



$\Phi(z)$ streng monoton



- Konfidenzintervall ist $[\hat{R}_T(f) - \varepsilon, \hat{R}_T(f) + \varepsilon]$
(Konfidenzlevel $1-2\delta$)

Konfidenzintervalle

- $\hat{R}_T(f)$ ist annähernd normal-verteilt



Konfidenzintervalle

■ Beispiel:

$\hat{r} = 0.08$ beobachtetes empirisches Risiko, $m=100$


$$s_{\hat{r}} = \sqrt{\frac{0.08 \cdot 0.92}{100 - 1}} \approx 0.027 \quad \text{empirischer Standardfehler}$$

$\delta = 0.05$ Konfidenzlevel

$$\varepsilon \geq s_{\hat{r}} \Phi^{-1}(1 - \delta)$$

$$\varepsilon \geq 0.027 \cdot 1.645 \approx 0.045$$

$\Phi^{-1}(0.95)$ [Tabelle]



Einseitige Schranke: $R(f) \leq R_T(f) + \varepsilon$ mit 95% Konfidenz

Zweiseitige Schranke: $|R(f) - R_T(f)| \leq \varepsilon$ mit 90% Konfidenz

Students t-Verteilung

- Empirisches Risiko annähernd normalverteilt:

- ◆
$$p(\hat{R}_T(f) = \hat{r} | r) = B(m\hat{r} | r, m)$$
$$\approx N\left(\hat{r} | r, \frac{r(1-r)}{m}\right)$$
$$= N\left(\frac{\hat{r} - r}{\sigma_{\hat{r}}} | 0, 1\right)$$
 Einfache Charakterisierung der Verteilung des empirischen Fehlers

- Problem: Risiko muss bekannt sein, damit wir Varianz bzw. Standardfehler bestimmen können.

- ◆
$$\sigma_{\hat{r}}^2 = \frac{r(1-r)}{m}; \quad \sigma_{\hat{r}} = \sqrt{\frac{r(1-r)}{m}}$$

- Nur das empirische Risiko ist gegeben.

Students t-Verteilung

- Standardisiertes empirisches Risiko mit geschätzter Varianz

$$\frac{\hat{R}_T(f) - R(f)}{s_{\hat{f}}}$$


folgt einer Students t-Verteilung mit $m-1$ Freiheitsgraden (ähnlich Normalverteilung, aber mehr Wahrscheinlichkeitsmasse in den Außenbereichen).

- Aber für große m konvergiert Students t-Verteilung wieder gegen die Standardnormalverteilung

$$\frac{\hat{R}_T(f) - R(f)}{s_{\hat{f}}} \sim N\left(\frac{\hat{R}_T(f) - R(f)}{s_{\hat{f}}} \mid 0,1\right) \quad [\text{approximativ, für große } m]$$

Students t-Verteilung

Dichtefunktionen von t-verteilten Zufallsgrößen mit unterschiedlichen Freiheitsgraden



$$\lim_{m \rightarrow \infty} t \left(\frac{\hat{r} - r}{s_{\hat{r}}} \mid m \right) = N \left(\frac{\hat{r} - r}{s_{\hat{r}}} \mid 0, 1 \right)$$

$$f_n(x) = \frac{\Gamma\left(\frac{n+1}{2}\right)}{\sqrt{n\pi}\Gamma\left(\frac{n}{2}\right)} \left(1 + \frac{x^2}{n}\right)^{-\frac{n+1}{2}}$$

$$\Gamma(x) = \int_0^{+\infty} t^{x-1} e^{-t} dt$$

Konfidenzintervalle

- Vorsicht bei der Interpretation von Konfidenzintervallen: die Zufallsvariable ist das empirische Risiko \hat{r} und das davon abgeleitete Intervall ε , nicht das echte Risiko $R(f)$.
- **Richtig:**
"Die Wahrscheinlichkeit, bei einem Experiment ein Konfidenzintervall zu erhalten, das den echten Fehler enthält, ist 90%"
- **Falsch:**
"Wir haben ein Konfidenzintervall ε erhalten. Die Wahrscheinlichkeit, dass der echte Fehler im Intervall liegt, ist 90%"

Überblick


- Hypothesenbewertung, Risikoschätzung
- Anwendungen/Beispiele
- Konfidenzintervalle
- Roc-Analyse

Klassifikator / Entscheidungsfunktion

- Für eine binäre Klassifikation ($y = +1$ oder -1) wird oft eine kontinuierliche Entscheidungsfunktion $f(x)$ gelernt.
 - ◆ Z.B. lineares Modell

$$f_{\mathbf{w}}(\mathbf{x}) = \mathbf{w}^T \mathbf{x} = \sum_{i=1}^m w_i x_i$$

- Je größer $f(x)$, desto wahrscheinlicher ist, dass x zur Klasse $+1$ gehört
 - ◆ Z.B. logistische Regression



$$\sigma(f(x)) = \frac{1}{1 + \exp(-f(x))}$$

Klassifikator / Entscheidungsfunktion

- Wie bestimmen wir Klassenentscheidung +1/-1 aus $f(\mathbf{x})$?
- Allgemeine Lösung:

$$\text{Vorhersage} = \begin{cases} +1 : f(\mathbf{x}) \geq \theta \\ -1 : \text{sonst} \end{cases}$$

- Der Wert für θ verschiebt „false positives“ zu „false negatives“.
- Optimaler Wert hängt von Kosten einer positiven oder negativen Fehlklassifikation ab.

Evaluation von Klassifikatoren und Entscheidungsfunktionen

- Fehlklassifikationswahrscheinlichkeit
 - ◆ Häufig nicht aussagekräftig, weil $P(+1)$ sehr klein.
 - ◆ Wie gut sind 5% Fehler, wenn $P(+1)=3\%$?
 - ◆ Idee: Nicht Klassifikator bewerten, sondern Entscheidungsfunktion.
- Receiver Operating Characteristic (ROC-Kurve)
 - ◆ Bewertet Entscheidungsfunktion,
 - ◆ Jeder Punkt auf der ROC Kurve entspricht einem Schwellwert θ
 - ◆ Fläche unter ROC-Kurve = $P(\text{positives Beispiel hat höheren f-Wert als negatives Beispiel})$

ROC-Analyse


- Entscheidungsfunktion + Schwellwert = Klassifikator

$$\text{Vorhersage} = \begin{cases} +1: f(\mathbf{x}) \geq \theta \\ -1: \text{sonst} \end{cases}$$

- ◆ Fehler hängen vom Schwellwert ab
 - ◆ Großer Schwellwert: Mehr positive Bsp falsch.
 - ◆ Kleiner Schwellwert: Mehr negative Bsp falsch.
- ROC-Analyse: Bewertung der Entscheidungsfunktion unabhängig vom konkreten Schwellwert.
 - Charakterisieren das Verhalten des Klassifikators für alle möglichen Schwellwerte.

ROC-Kurven

- Rate der „False Positives“ und „True Positives“ in Abhängigkeit des Schwellwertes
 - ◆ X-Achse: „False Positive Rate“
 - ◆ Y-Achse: „True Positive Rate“



	Vorhersage „+“	Vorhersage „-“
Echtes Label „+“	TP	FN
Echtes Label „-“	FP	TN

$$FPR = \frac{FP}{N}$$

$$TPR = \frac{TP}{P}$$

$$N = FP + TN$$


$$P = TP + FN$$

Bestimmen der ROC-Kurve von f

- Annahme: kein $f(\mathbf{x}) = f(\mathbf{x}')$ für $\mathbf{x} \neq \mathbf{x}'$.
- Generiere Liste L aller Instanzen \mathbf{x} , absteigend sortiert nach $f(\mathbf{x})$
- P = Anzahl positiver Instanzen, N = Anzahl negativer Instanzen
- $TP = FP = 0$
- Für $i = 1$ bis $\text{Länge}(L)$
 - ◆ $\mathbf{x} = i$ -tes Element von L
 - ◆ Wenn \mathbf{x} positive Instanz: $\text{increment}(TP)$
 - ◆ Wenn \mathbf{x} negative Instanz: $\text{increment}(FP)$
 - ◆ Zeichne neuen Punkt mit Koordination $(FP/N, TP/P)$

Flächeninhalt der ROC-Kurve

- Flächeninhalt AUC kann durch Integrieren (Summieren der Trapez-Flächeninhalte) bestimmt werden.




- x_+ = zufällig gezogenes Positivbeispiel
- x_- = zufällig gezogenes Negativbeispiel
- Theorem: $AUC = P(f(x_+) > f(x_-))$.

Precision / Recall

- Alternative zur ROC-Analyse.
- Stammt aus dem Information Retrieval.
- $\text{Precision} = \frac{TP}{TP + FP}$ ← Alle Instanzen mit Vorhersage „+“
- $\text{Recall} = \frac{TP}{TP + FN}$ ← Alle Instanzen mit echtem Label „+“
- Precision: $P(\text{positiv} \mid \text{positiv vorhergesagt})$
- Recall: $P(\text{positiv vorhergesagt} \mid \text{ist positiv})$

Precision / Recall Trade-Off



- Precision-/Recall-Kurven
- Welcher Klassifikator ist der Beste / Schlechteste

F-Measure, Breakeven Point

- Zusammenfassungen der Kurve in einer Zahl:
 - ◆ F-Measure: Harmonisches Mittel über Precision und Recall, maximiert über Schwellwert θ

$$\text{F-measure} = \frac{2 \cdot \text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}}$$

- ◆ Precision-Recall-Breakeven-Point: Es gibt einen Punkt θ auf der Kurve für den gilt $\text{Precision}(\theta) = \text{Recall}(\theta) =: \text{PRBEP}$