

Maschinelles Lernen II - Fortgeschrittene Verfahren

V02 Semi – überwachttes Lernen

Semi Supervised Learning (SSL)

Sommersemester 2017

Prof. Dr. J.M. Zöllner, Prof. Dr. R. Dillmann

INSTITUT FÜR ANGEWANDTE INFORMATIK UND FORMALE BESCHREIBUNGSVERFAHREN
INSTITUT FÜR ANTHROPOMATIK UND ROBOTIK



Inhalt

■ Motivation und Begriffsklärung

- Das SSL - Problem
- Grundannahmen
- Formalisierung
- Induktiv $\leftrightarrow$ Transduktiv

■ SSL - Methoden:

- Self-Learning und Co-Training
- Generative Modelle
- Low-Density Separation
- Graph basierte Modelle
- Änderung der Repräsentation

■

Grundparadigmen

■ Überwachtes Lernen

- Gelabelte Trainingsdaten: Paare (X, Y)
- Finde eine Funktion h die X (Merkmalsraum) auf Y abbildet (z.B. Klassen)

■ Unüberwachtes Lernen

- Ungelabelte Daten aus dem Merkmalsraum X
- Strukturen und Labels der Daten (z.B. durch Cluster-Verfahren) finden
- Oft auch Dichte-(Träger)-Schätzung (siehe ML I – SVM)

■ Semi-Überwachtes Lernen

- Einige, aber meist wenige gelabelte Lerndaten
- Viele ungelabelte Daten
- Finde eine Funktion h die X (Merkmalsraum) auf Y abbildet (z.B. Klassen)

Wieso benötigt man dafür eine Lösung?

- Weil bessere Performanz mit minimalen Kosten („for free“) angestrebt wird
- Gründe:
 - Ungelabelte Daten sind billig z.B.
 - Sprache,
 - Kognitive Fzg. => Videodatenaufzeichnung rel. billig
 - Bilder/Videos im web , youtube, ...
 - Gelabelte Daten sind relativ teuer und schwer zu erzeugen
 - Annotation von Sprache: Beispiel 400h Annotation für ca. 1h Sprachdaten, ähnlich bei Videodaten etc.....
 - Manuelle Annotation ist teuer und zudem anstrengend
 - „Experten“ sind nötig
 - Annotationen sind auch fehleranfällig

Grundannahmen

■ Typische Annahmen für das Lernen


■ Gleichmäßigkeit für überwachtes Lernen (Smoothness Assumption):

- Wenn zwei Datenpunkte x_1 , x_2 „nahe“ beieinander sind dann sollten auch die Ausgaben y_1 , y_2 „ähnlich“ sein

■ Gleichmäßigkeit für Semi-überwachtes Lernen:

- Wenn zwei Datenpunkte x_1 , x_2 in einer dichten Region „nahe“ beieinander sind, dann sollten auch die Ausgaben y_1 , y_2 „ähnlich“ sein

→ wenn zwei Datenpunkte durch einen Pfad hoher Dichte verbunden sind (i.A. gehören dem gleichen Cluster an) dann sind ihre Ausgaben ähnlich




Abgeleitete Grundannahmen

■ Cluster oder Dichte Annahme

- Wenn zwei Datenpunkte im selben („dichten“) Cluster sind, dann sind sie in derselben Klasse
- ➔ eine Trennung sollte in einer Region niedriger Dichte (zw. den Clustern) liegen

■ Manigfaltigkeit-Annahme (Manifold Assumption)

- Hochdimensionale Daten haben eine Abbildung in einen i.A. anders dimensional Raum (Manigfaltigkeitsraum) in dem sich ihre Strukturen abbilden (unterscheiden/ erhalten)
- ➔ Dieser Raum kann dann für die Berechnung des geodäsischen Abstand benutzt
- ➔ approximative Implementierung der Gleichmäßigkeitsannahme



Wie könnte SSL realisiert werden

■ Möglichkeiten

■ SSL als Erweiterung des überwachten Lernens

→ SSL ist überwachtes Lernen mit zusätzlichen Informationen über die Verteilung der Daten in X

■ SSL als Erweiterung des unüberwachten Lernens

→ SSL ist unüberwachtes Lernen mit zusätzlichen Einschränkungen und Informationen über die Cluster/Strukturen

Das SSL - Problem

■ SSL-Problem:

- Verwendung von gelabelten und ungelabelten Daten um bessere Hypothesen zu erzeugen

■ Bessere Hypothesen heißt → 2 untere Güte-Schranken:

- SSL kann und sollte verglichen werden mit (und besser sein als):
 - Ergebnis des überwachten Lernens mit ausschließlich gelabelten Daten
 - Ergebnis des unüberwachten Lernens mit allen Lerndaten (ohne Labels)
- Vergleich mit diesen beiden unteren Schranken → Informationen darüber, ob die Annahme, die bei dem semi-überwachten Lernen gemacht wird gilt oder ob der verwendete Ansatz (Modell) diese verletzt

■ Leider:

- „as we all know - there is no free lunch...“
→ Vorwissen oder korrekte Annahmen nötig

Formalisierung

- Instanzen (Feature – Vektor):
label:
- Hypothese:
- Gelabelte Daten
- Ungelabelte Daten:
vorhanden beim Trainieren
- Üblicherweise gilt:
- Neue Daten:
nicht vorhanden beim Trainieren

$$x \in X$$

$$y \in Y$$

$$h : X \rightarrow Y$$

$$(X_l, Y_l) = \{(x_{1:l}, y_{1:l})\}$$

$$X_u = \{x_{l+1:n}\}$$

$$l \ll n$$

$$X_{test} = \{x_{n+1:....}\}$$

Induktiv vs. Transduktiv

■ Gegeben die Daten

- Gelabelte und ungelabelte Lerndaten
- Ungelabelte Daten

■ Induktives Lernen (d.h. auch semi - überwachtes Lernen):

- Ziel ist das Schätzen einer Hypothese


$$h : X \rightarrow Y$$

- Die auch unbekannte Daten „gut“ abbildet

■ Transduktives Lernen:

- Ziel ist das Labeln der ungelabelten Daten
- (kann! auch das Labeln neuer Daten sein)
- Das Finden einer Hypothese ist nicht das Ziel (kann aber erfolgen)

Induktion (Deduktion) Transduktion



[Learning from Data: Concepts, Theory and Methods.
V. Cherkassky, F. Mulier. Wiley, 1998.]

- Vorsicht: einige Verfahren heißen zwar „transductive ...“ sind aber eher induktiv (z.B. die ursprüngliche transductive SVM)

■ Unterschiedliche Problemstellungen:

- Überwachtes Lernen (Klassifikation/Regression) $\{(x_{1:n}, y_{1:n})\}$
- Semi-überwachte Klassifikation/Regression $\{(x_{1:l}, y_{1:l}), x_{l+1:n}, x_{test}\}$
- Transduktive Klassifikation/Regression $\{(x_{1:l}, y_{1:l}), x_{l+1:n}\}$
- Semi-überwachtes Clustern $\{x_{1:n}, \text{must-links, cannot-links}\}$
- Unüberwachtes Lernen $\{x_{1:n}\}$

■ Fokus in MLII auf Algorithmen für die Klassifikation

Verschieden Ansätze

- Erste Algorithmen
 - Self-Training & Co-Training
- Generative probabilistische Modelle (Generative Probabilistic Models)
 - EM for Gaussian Mixtures
- Dichte Trennung (Low-Density Separation)
 - „Transduktive“ SVM
- Graph basierte Modelle / Methoden
 - Methoden bei denen die Daten als Knoten eines Graphs repräsentiert sind und die Kanten die jeweiligen Abstände enthalten
- Änderung der Repräsentation
 - unüberwachtes Lernen (z.B.: Clustern) um neue (i.A. niedrig dimensionale) Repräsentationen der Daten zu erhalten
 - Lernen der Zuordnung der Cluster zu Klassen

Selbst-Lernen (Self – Training)

- Grundidee: Sukzessive Verwenden der ungelabelten Daten, die durch die gelernte Hypothese eine hohe Konfidenz der Prädiktion erreichen
(Konfidenz $\sim$ Wahrscheinlichkeit der Klassenzugehörigkeit)
- Grundalgorithmus – Wrapper
- Wiederhole



- Trainieren mit gelabelten Daten

$$h \leftarrow (X_l, Y_l)$$

- Auswerten der ungelabelten Daten

$$h(x), \forall x \in X_u$$

- Einfügen konfidenter Daten
zu den Trainingsdaten


$$(X_l, Y_l) \leftarrow (X_l, Y_l) \cup \{(x, h(x)) \mid x \in X_u, h(x) - \text{hohe Konf.}\}$$

- Variationen – Hinzunehmen neuer Daten

- Nur konfidente neue Beispiele
- Alle Beispiele
- Mit Gewichtung anhand der Konfidenz (↩ Lernverfahren muss dies erlauben)

Beispiel


- Ziel : Klassifikation Sonnenfinsternis



Beispiel


■ Gegeben

- Einige gelabelte Daten: Blau – Sonnenfinsternis, rot – andere
- Viele ungelabelte Daten



Beispiel – nur zur Verdeutlichung

- Repräsentation (Feature Vektor)
 - Jedes Bild wird in kleine patches aufgeteilt
 - 10x10 Grid, zufällige Größe zw.10-20 pixels
 - (Normalisieren der patches)
- Definiere 200 Datensätze (“visual words”)
 - Clustern z.B. mit k-means clustering
 - Klassifiziere jeden patch durch seinen Clustervertreter (visual word)
- Bilder werden repräsentiert durch einen Satz (Vektor) = Häufigkeiten solcher „Visuellen Wörtern“
- Verwende neue Repräsentation (Vektor)




(Lässt sich auch anders realisieren)

Beispiel

- Trainiere naiven Bayes-Klassifikator auf den ursprünglichen 2 Bildern



- Klassifiziere ungelabelte Daten, sortiert nach Konfidenz $\leftarrow \log p(y=\text{Sonnenfinsternis} \mid x)$




Beispiel

- Hinzufügen der Daten zu den Lerndaten (mit Klassifikation)



- Neu-Trainieren des Klassifikators und wiederholen



Selbst – Lernen Diskussion

- Weit verbreitet und vermutlich ältester SSL – Ansatz (1965 -70)
 - Wrapper Algorithmus anwendbar für alle überwachten Lernmethoden
 - Startet auf gelabelten Daten
 - In jeder Iteration werden ungelabelte Daten gelabelt, abh. von der Entscheidungsfunktion
 - Bezeichnungen: self-learning, self-labeling, decision-directed learning

- Diskussion
 - Kann effektiv sein
 - Aber es ist nicht genau bestimmt, wie das Ergebnis ist (und abhängig von der Methode des überwachten Lernens)
 - Nicht methodisch festgelegt, welche Annahmen über das Problem getroffen werden

Selbst – Lernen Diskussion

■ Vorteile

- Sehr einfache semi-überwachte Lernmethode
- Wrapper – passend zu existenten auch komplexen Klassifikatoren /etc...
- Oft angewandt in realen Anwendungen wie z.B. Sprachanalyse

■ Nachteile

- Frühe Fehlentscheidungen können sich verstärken
 - Heuristische Lösung: Daten „un-labeln“ sofern ihre Konfidenz unter einen Schwellwert fällt
- Generelle Analyse kompliziert
 - Nur für Spezialfälle ist eine geschlossen, formale Analyse möglich
 - In Spezialfällen entspricht Selbst-Lernen dem EM – Ansatz (siehe GMM)


Mit-Lernen (Co – Training)

■ Idee (nach Blum & Mitchell '98)


■ Annahme:

- Features können in 2 Mengen aufgeteilt werden (Feature-Split) somit gilt für jeden Vektor:
- Jede Untermenge ist ausreichend um eine gute Lernmaschine (im weiteren Klassifikator) einzutrainieren

$$x = [x^{(1)}, x^{(2)}]$$



$X^{(2)} - \text{view}$



- Wichtig: die Featurevektoren $x^{(1)}, x^{(2)}$ sind voneinander unabhängig

Mit-Lernen (Co – Training)

■ Lern - Ansatz

- Verwende den Wrapper – Ansatz
- 2 unabhängige Klassifikatoren werden auf je einer Featuremenge trainiert und auf die ungelabelteten Daten angewendet

$$\left(X_l^{(1)}, Y_l\right) \rightarrow h^{(1)} \quad \left(X_l^{(2)}, Y_l\right) \rightarrow h^{(2)}$$


- Wenige Daten hoher Konfidenz (mit oder ohne Übereinstimmung der Klassifikatoren) werden zu dem jeweilig anderen Lerndatensatz hinzugenommen
- Neutrainieren der Klassifikatoren mit dem erweiterten Datensatz
- Wiederholen

■ Erweiterung

- Demokratisches Co-Training: Erweiterung zu mehr als 2 Basisklassifikatoren
→ Mehrheitsentscheidung nötig um neue Daten hinzuzufügen

Co-Training Beispiel

■ Bild und Textklassifikation von Webseiten



Co-Training Beispiel

■ Merkmalsmengen

- Jede Instanz wird durch zwei Merkmalsvektoren dargestellt

$$x = [x^{(1)}, x^{(2)}] = [\textit{Bildvektor}, \textit{Webseiten - Text - Merkmale}]$$

- Natürliche Untermengen (multiple – Sicht)

■ Umsetzen der Co-Training Idee

- Verwenden: einen Bildklassifikator und einen Textklassifikator
- Gegenseitig Zulieferung neuer Lerndaten


■ Auswertung

$$h^{(1)}(x^{(1)}), h^{(2)}(x^{(2)})$$

oder

$$h^{(1)}(x^{(1)}) = h(x) = h^{(2)}(x^{(2)})$$

$$h(x) = h^{(1)}(x^{(1)}) * h^{(2)}(x^{(2)})$$



Co-Training Diskussion

■ Vorteile

- Wrapper Methode – anwendbar auf alle existierenden Klassifikatoren
- Weniger anfällig für Missentscheidungen als Selbstlernen

■ Nachteile

- „Natürliche“ Featureaufteilung ggf. nicht vorhanden
- Modelle die die vollständige Featuremenge benutzten erreichen oft bessere Ergebnisse

Co-Training Varianten

■ Fake Feature Split

- Zufällige, künstliche Aufteilung der Merkmale
- Co-Training wie bisher

■ Multi-View-Ansatz

- Kein Feature Split
- Trainiere mehrere Klassifikatoren
- Klassifizierung der ungelabelten Daten mit allen Klassifikatoren
- Verwende Mehrheitsentscheidung für neue Labels

■ CO-EM


- Nutzung aller Daten
- Jeder Klassifikator labelt die Daten X_u probabilistisch
- Daten (x,y) werden probabilistisch gewichtet genutzt, mit Gewicht $p(y/x)$

Case Study: Recognition of ADL (Activities of Daily Living)


- Dataset called PLCouple1 from PlaceLab - MIT
 - ▶ data from a couple - living 10 weeks in PlaceLab-apartment
 - ▶ 'normal' daily routine
 - ▶ 104 hours are annotated from 15 separate days
 - ▶ publicly available only 68 hours from 9 separate days
 - ▶ 9 activities studied
 - actively watching TV, dishwashing, eating, grooming, hygiene, meal preparation, reading paper/book/magazine, using computer, using phone
 - ▶ two different modalities used
 - room-level movement (infrared sensor)
 - 3 3D-accelerometers (worn by male)
 - ▶ experimental protocol: leave-one-day-out cross-validation

Case Study: Recognition of ADL (Activities of Daily Living)

- Reduce annotation effort to recognize ADLs
 - ▶ Semi-Supervised Learning of Activities



(a) Results based on acceleration data



(b) Results based on infra-red data

- ▶ Best Result
 - acceleration: (53.6% supervised) - (44.4% co-training)
 - infrared: (41.6% supervised) - (50.3% co-training)

Case Study: Recognition of ADL (Activities of Daily Living)

- Active Learning and Sampling of Labels
 - ▶ start with 1.3% labels (124 labels for 9 activities)
 - ▶ let user label data if
 - a, both classifiers have low score
 - b, the classifiers contradict each other

Acceleration				Infra-red			Combined		
Labeled	Supervised	Active - low scores	Active - conflicts	Supervised	Active - low scores	Active - conflicts	Supervised	Active - low scores	Active- conflicts
12.5%	33.4%	54.3%	56.0%	25.8%	45.9%	30.2%	34.3%	62.8%	61.0%
6.3%	29.7%	58.7%	56.9%	29.5%	40.9%	30.9%	34.3%	65.4%	59.5%
2.5%	27.3%	52.5%	50.3%	34.5%	33.3%	41.2%	36.0%	57.2%	56.6%
1.3%	28.3%	46.1%	46.5%	22.5%	40.3%	32.3%	27.1%	54.9%	52.5%

- ▶ Best result:
 - acceleration: (53.6% supervised) - (58.7% active learning)
 - infrared: (41.6% supervised) - (45.9% active learning)
 - combined: (65.4% active learning)

Case Study: Recognition of ADL (Activities of Daily Living)



- Comparison each sensor modality
 - ▶ active learning most profitable
 - ▶ co-training only profitable for infrared - as its profits from the better performance of the accelerometers

Acceleration		Infra-red	
Active - low scores	58.7%	Co-training	50.3%
Active - conflicts	56.9%	Active - low scores	45.9%
Supervised	53.6%	Supervised	41.6%
Co-training	44.4%	Active - conflicts	41.2%
Self-training	38.0%	Self-training	38.0%


- Combination of both sensor modalities
 - ▶ active learning: 65.4%

Verschieden Ansätze

- Erste Algorithmen
 - Self-Training & Co-Training
- Generative probabilistische Modelle (Generative Probabilistic Models)
 - EM for Gaussian Mixtures
- Dichte Trennung (Low-Density Separation)
 - „Transduktive“ SVM
- Graph basierte Modelle / Methoden
 - Methoden bei denen die Daten als Knoten eines Graphs repräsentiert sind und die Kanten die jeweiligen Abstände enthalten
- Änderung der Repräsentation
 - unüberwachtes Lernen (z.B.: Clustern) um neue (i.A. niedrig dimensionale) Repräsentationen der Daten zu erhalten
 - Lernen der Zuordnung der Cluster zu Klassen


Generative Modelle / Methoden

- Generative Algorithmen nutzen eine Schätzung der Verteilung der Daten für die Klassen
- ➔ Zusätzliche Information der Verteilung der Daten sind sinnvoll !!
 - Ausgehend davon, dass Klassen kohärente Daten enthalten z.B. normalverteilt ➔ Geschätzte Entscheidungsgrenze wandert je nach Verteilung der Daten




Generative Modelle / Methoden

- Generative Algorithmen nutzen eine Schätzung der Verteilung der Daten für die Klassen
- ➔ Zusätzliche Information der Verteilung der Daten sind sinnvoll !!
 - Ausgehend davon, dass Klassen kohärente Daten enthalten z.B. normalverteilt ➔ Geschätzte Entscheidungsgrenze wandert je nach Verteilung der Daten




Generative Modelle / Methoden

- Generative Algorithmen nutzen eine Schätzung der Verteilung der Daten für die Klassen
- ➔ Zusätzliche Information der Verteilung der Daten sind sinnvoll !!
 - Ausgehend davon, dass Klassen kohärente Daten enthalten z.B. normalverteilt ➔ Geschätzte Entscheidungsgrenze wandert je nach Verteilung der Daten




Generative Modelle / Methoden

- Generative Algorithmen nutzen eine Schätzung der Verteilung der Daten für die Klassen
- ➔ Zusätzliche Information der Verteilung der Daten sind sinnvoll !!
 - Ausgehend davon, dass Klassen kohärente Daten enthalten z.B. normalverteilt ➔ Geschätzte Entscheidungsgrenze wandert je nach Verteilung der Daten



Generative Modelle / Methoden

- Generative Algorithmen nutzen eine Schätzung der Verteilung der Daten für die Klassen
- ➔ Zusätzliche Information der Verteilung der Daten sind sinnvoll !!
 - Ausgehend davon, dass Klassen kohärente Daten enthalten z.B. normalverteilt ➔ Geschätzte Entscheidungsgrenze wandert je nach Verteilung der Daten



Generative Modelle / Methoden

- Zunächst (iteratives) Schätzen eines probabilistischen, parametrisierten Verbundmodells,


$$p(x, y | \theta)$$

dann Entscheidung unter Verwendung des Modells

- Modelle
 - Gaussche Mixturen (GMM)
 - Multinomiale Mixturen (Naive Bayes)
 - Hidden Markov Modelle (HMMs)
 - ...
- Im Gegensatz dazu schätzen (nutzen) die diskriminativen Modelle direkt:
$$p(y | x)$$
 - z.B. SVM (support vector machines), CRF(conditional random fields) etc.


Einfaches Beispiel

- Gegeben folgende gelabelte Daten (X_l, Y_l)




- Unter der Annahme, dass jede Klasse eine gaußsche Verteilung der Daten im Merkmalsraum hat, welches ist die wahrscheinlichste Trennung der Daten?

Einfaches Beispiel – Modell der Verteilung



Einfaches Beispiel - Trennung



Einfaches Beispiel - Trennung

- Gegeben die Modelparameter

$$\theta = \{\pi_1, \pi_2, \mu_1, \mu_2, \Sigma_1, \Sigma_2\}, \quad \pi_y = p(y)$$

- Gilt
$$p(x|\theta) = \sum_{y=1}^2 p(x|\theta_y)\pi_y = p(x|\mu_1, \Sigma_1)\pi_1 + p(x|\mu_2, \Sigma_2)\pi_2$$


- Und die Klassenwahrscheinlichkeit

$$x \in X_u, \quad p(y|x, \theta) = \frac{p(x|\theta_y)\pi_y}{p(x|\theta)}$$

es gilt (lt. Bayes)


$$p(y|x) = \frac{p(x|y)p(y)}{\int_{y'} p(x|y')p(y')}$$

Einfaches Beispiel – Trennung (auf Basis gelabelter Daten)




Einfaches Beispiel – Neue Daten

- Wenn zu den gelabelten Daten (X_l, Y_l) noch X_u hinzukommen?




Einfaches Beispiel – Trennung durch das beste Modell



Einfaches Beispiel – Wieso?

- Weil hier GMM (gaussian mixture models) verwendet werden und
- Für die Bestimmung der Parameter θ ergeben sich unterschiedliche Optimierungsaufgaben (Maximierung):



Generative probabilistische Modelle – Grundverfahren

- 1. Wähle ein generatives Modell

$$p(x, y | \theta)$$

- 2. Finde Maximum likelihood Schätzung (MLE) auf gelabelte und ungelabelte Daten

$$\theta^* = \arg \max_{\theta} p(X_l, Y_l, X_u | \theta)$$

EM (expectation maximization)

- 3. Bestimme Klassenzugehörigkeit entsprechend der Bayes'schen Regel

$$p(y | x, \theta^*) = \frac{p(x, y | \theta_y^*)}{\sum_{y'} p(x, y' | \theta^*)} = \frac{p(x | \theta_y^*) p(y | X, Y)}{p(x | \theta^*)}$$

EM – Algorithmus für GMM

- Starte mit MLE $\theta = \{\pi_1, \pi_2, \mu_1, \mu_2, \Sigma_1, \Sigma_2\}$ auf (X_l, Y_l)
 - E- Schritt
 - Berechne Wahrscheinlichkeit für alle $x \in X_u, p(y|x, \theta) = \frac{\pi_y p(x|\theta_y)}{p(x|\theta)}$
 - Setzte Label (je nach Maximum) $y_u = 1$ bzw. $y_u = 2$
 - M – Schritt
 - Update von θ jetzt auch mit (X_u, Y_u) (soft label)
 - A-priori-Klassenwahrscheinlichkeit = Anteil der Daten mit Klasse $i = \pi_i$
 - (gewichteter) Mittelwert der Daten der Klasse $i = \mu_i$
 - (gewichtete) Kovarianz der Daten der Klasse $i = \Sigma_i$
 - Iteriere
- Kann als Sonderfall des Selbstlernens gesehen werden

EM – Verallgemeinerung

■ Problem

- Beobachtete Daten $\mathcal{D} = (X_l, Y_l, X_u)$
- Versteckte Daten $\mathcal{H} = Y_u$

- Ziel: Finde θ so dass $p(\mathcal{D}|\theta) = \sum_{\mathcal{H}} p(\mathcal{D}, \mathcal{H}|\theta)$ maximiert wird

■ Ablauf und Eigenschaften

- EM startet mit θ_0
- E-Schritt: Bestimme Belegung $q(H) = p(H|D, \theta)$
- M – Schritt Maximiere $p(D|\theta) \geq \sum_H q(H) \ln p(D|H, \theta)$
(untere Schranke lt Jensen, i.A. einfacher zu berechnen)
- EM – verbessert somit iterativ θ
- EM konvergiert zu einem lokalen Maximum $p(D|\theta)$ in Abh. von θ

Generative Modelle für SSL

■ Grundsatz

- Maximierung von $p(X_l, Y_l, X_u | \theta)$
- Verwende optimales Modell für die Trennung
- EM ist nur eine Variante, andere Methoden existieren

■ Vorteile

- Klares, wohl definiertes Framework
- Kann sehr effektiv sein WENN das Modell korrekt ist


■ Nachteile

- Verifikation der Korrektheit des Modell meist nicht möglich
- EM – kann zu lokalen Minima führen
- Ungelabelte Daten können schaden wenn das Modell nicht korrekt ist

Generative Modelle für SSL

■ Beispiel

- Gegeben 2 Klassen mit der Annahme: gaußschen Verteilungen
- Wenig gelabelte Daten
- Viele ungelabelte Daten



- Je mehr ungelabelte Daten umso schlechter ...
(hoher likelihood der Modellbestimmung führt zu falscher Trennung)
- Annahme dieser gaußschen Verteilung „killed EM“ aber nicht SSL!
(z.B. durch Verwendung eines anderen Modells)

Generative Modelle für SSL – Erweiterungen

■ Heuristiken

- Generative Modelle erweitern um der Aufgabenstellung gerecht zu werden z.B. multiple Gausverteilungen pro Klasse (statt nur einer pro Klasse)

- Ungelabelte Daten gewichten mit $\lambda < 1$

→ Maximierung des „gewichteten“ Loglikelihood :

$$\ln p(X_l, Y_l, X_u | \theta) = \sum_{i=1}^l \ln p(x_i, y_i | \theta) + \lambda \sum_{i=l+1}^u \ln \left(\sum_{y=1}^2 p(x_i, y | \theta) \right)$$

→ Ungelabelte Daten fließen nur gewichtet in die Bestimmung des Modells ein

Verschieden Ansätze



- Erste Algorithmen
 - Self-Training & Co-Training
- Generative probabilistische Modelle (Generative Probabilistic Models)
 - EM for Gaussian Mixtures
- Dichte Trennung (Low-Density Separation)
 - „Transduktive“ SVM
- Graph basierte Modelle / Methoden
 - Methoden bei denen die Daten als Knoten eines Graphs repräsentiert sind und die Kanten die jeweiligen Abstände enthalten
- Änderung der Repräsentation
 - unüberwachtes Lernen (z.B.: Clustern) um neue (i.A. niedrig dimensionale) Repräsentationen der Daten zu erhalten
 - Lernen der Zuordnung der Cluster zu Klassen

Dichte Trennung (Low – density separation) mit SVM

■ Ziel



SVM
Labeled data **only**



Transductive SVM

Transduktive SVM

■ Annahme


- Ungelabelte Daten unterschiedlicher Klassen werden mit großem Rand getrennt – aber wie?

■ Naiver Ansatz

- Alle 2^u Möglichkeiten der Labels v. $X_u = \{x_{l+1:l+u}\}$ betrachten
- Trainiere SVM für alle Möglichkeiten
- Wähle SVM mit größtem Rand

■ Besser

- Integriere ungelabelte Daten in das Optimierungsproblem



Literatur

Chapelle, Schölkopf, Zien: „Semi – Supervised Learning“,

- MIT – Press, 2010

X. Zhu: „Semi-Supervised Learning Literature Survey“

- http://pages.cs.wisc.edu/~jerryzhu/pub/ssl_survey.pdf

K-R Müller, A.Zien: „Semi-Supervised Learning“

- Folien: https://ml01.zrz.tu-berlin.de/wiki/Main/SS09_MaschinellesLernen2

B. Schiele: Vorlesung ML

- Folien: <http://www.mis.tu-darmstadt.de/ml2>