

Gépi tanulás elmélete, 2016. őszi félév

December 12.

Tankönyv: S. Shalev-Shwartz, S. Ben-David: *Understanding Machine Learning: From Theory to Algorithms*, Cambridge University Press, 2015.

1. HÉT (szeptember 21-22)

- alapfogalmak, mintaméret véges hipotézis osztályokra realizálhatósági feltétellel (Corollary 2.3) [1-2. fejezet]
HF-1: 2.3 (tengelypárhuzamos téglalapok)
- PAC modell definíciója (realizálhatósági feltétellel), általános modell: agnosztikus PAC tanulhatóság általános veszteségfüggvénnyel [3. fejezet]
- példa: logikai változók konjunkcióinak tanulása: mintaméret és hatékony ERM algoritmus
- Hoeffding egyenlőtlenség (Lemma 4.5, bizonyítás nélkül)

2. HÉT (október 5-6)

- ϵ -reprezentatív minta, véges hipotézisosztály PAC tanulhatósága az általános modellben (agnosztikus PAC tanulhatóság általános veszteségfüggvénnyel) (Corollary 4.6) [4. fejezet]
- tanulóalgoritmusok számítási bonyolultsága (Definition 8.1) [8. fejezet]
- példa: tengelypárhuzamos téglalapok (és d -dimenziós általánosítás)
- példa nehéz feladatra: 3-tagú DNF kifejezések
HF-2: gráf 3-szinezhetőség visszavezetése konzisztens 3-tagú DNF hipotézis keresésére
HF-3: 8.3 (3-tagú DNF kifejezések tanulásának bonyolultsága)
- 3-tagú DNF kifejezések hatékony tanulhatósága bővebb hipotézis osztállyal

- VC-dimenzió (Definition 6.5) [6. fejezet]
- példa: tengelypárhuzamos téglalapok (és d -dimenziós általánosítás)
- PAC tanulás alaptétele (Theorem 6.7, 6.8, bizonyítás nélkül)
- Sauer lemma (Lemma 6.10, bizonyítás nélkül)
HF-4: 6.6 (logikai változók konjunkciói)

3. HÉT (október 19-20)

- Sauer lemma bizonyítása (a könyvbelitől kissé különbözik)
- félterek tanulása (lineáris programozás, perceptron algoritmus, félterek VC-dimenziója) [9.1 alfejezet]
HF-5: Legyen $\mathcal{X} = \{0, 1\}^n$. Legfeljebb hány iterációt hajt végre a perceptron algoritmus a többségi függvény tanulásakor?
- Boosting (felerősítés) [10. fejezet, a 10.1.1 alfejezetet nem vettük részletesen]
HF-6: 10.3
- **Megjegyzés:** a házi feladatok megoldásainak leírását elosztjuk és a megoldásokat közzétesszük. A vizsgán csak ezek szerepelnek.
- **Megjegyzés:** el lehet kezdeni a kiselőadások témáján gondolkozni. Akinek van javaslata, emailezhet (turán@inf.u-szeged.hu).

4. HÉT (november 2-3)

- Winnow algoritmus
- konvex tanulási feladatok [12. fejezet, a 12.1.3, 12.2.1 alfejezeteket nem vettük]
- gradiens módszer, szubgradiens, sztochasztikus gradiens módszer [14. fejezet: csak a fogalmak, valamint a 14.2 következmény és a 14.8 tétel állításai bizonyítás nélkül]
- SVM (support vector machines) [15.1 fejezet: 15.1 és 15.2 alfejezetek; a minta méretre vonatkozó részeket nem vettük]
- kernel módszer [16. fejezet: 16.1 alfejezet és 16.1 példa]

5. HÉT (november 16)

- neuronhálók [20. fejezet: 20.1 - 20.4 alfejezetek, a 20.3 tételt nem vettük]
- backpropagation algoritmus: Jacobi mátrix, láncszabály vektor értékű függvényekre

6. HÉT (november 30, december 1)

- adalékok a 4. hét anyagához:
 - regularizált loss minimizáció (RLM), Tyihonov regularizáció [13.1 fejezet, a 13.1.1 alfejezet nélkül]
 - Corollary 13.9 (az RLM módszerre adott “PAC-like guarantee”; miben különbözik a szokásos fogalomtól?, ld. lábjegyzet a Corollary 13.9-hez és a következő feladat)
HF-7: 13.1
 - félterek agnosztikus tanulása: Corollary 15.7 (az RLM-re vonatkozó általános tétel alkalmazása a Soft-SVM feladatra; megjegyzés: a minta méret nem függ a VC-dimenziótól, de függ az eloszlástól)
 - string kernel
- deep learning neuronhálókra (Tóth László előadása)