

NEURÁLIS HÁLÓZATOK 2018/19/2 – ellenőrző kérdések / vizsga tételsor

-
- 1.) Neurális számítási paradigma jellemzői. Tanuló rendszerek általános felépítése, alkalmazásai módja. Milyen feladatok esetén célszerűek és melyeknél kerülendőek?
-
- 2.) Elemi neuronok (perceptron, adaline) felépítése, tanítása, működése. Ezek szeparáló képessége, perceptron kapacitás definíciója.
-
- 3.) Mit értünk neurális hálók tanulása / tanítása alatt? Mi az ellenőrzött, illetve a nem ellenőrzött tanítás lényege? A tárgy keretén belül taglalt megközelítések mely probléma típushoz igazodnak?
-
- 4.) Ellenőrzött tanulás numerikus eljárásai. Veszteségfüggvény, költségfüggvény definíciója. Szélsőérték-kereső eljárások: másodrendű, illetve elsőrendű módszerek működése.
-
- 5.) GD különböző változatai (momentum, Nyeszterov mom., adaptív eljárások). Hasonlítsa össze ezeket a Newton módszerrel! Milyen gyakorlati megfontolásokat érdemes alkalmazásuk során követni. Adaline esetén mi a GD konvergenciájának a feltétele?
-
- 6.) Sztochasztikus szélsőérték kereső eljárások. Tanuló rendszerekben történő alkalmazásuk sajátosságai. Hatásuk különböző szélsőérték kereső eljárások esetén. Alkalmazásuk során milyen megfontolásokat érdemes követni?
-
- 7.) Előre csatolt többrétegű perceptron (MLP) felépítése és tanítása. Hiba-visszaterjesztés (BP) eljárás algoritmus, δ szabály származtatása. Newton iteráció alapú súlytanulás, Levenberg-Marquardt eljárás.
-
- 8.) Neurális hálózatok képessége: függvényapproximáció elvi eredményei. Elvi eredmények gyakorlati alkalmazásának kérdései (MLP, RBF, SVM esetén).
-
- 9.) MLP tervezésének, tanításának gyakorlati kérdései. Tanítás felügyelete, tanulási görbék értelmezése. MLP általánosító képességének kérdése. Mi a korai leállás, illetve a kereszt validáció?
-
- 10.) Bázisfüggvényes hálók motivációja, működése. Radiális bázisfüggvényes háló (RBF) konstrukciója (OLS eljárás, hiba-visszaterjesztéssel tanítás), összehasonlítása az MLP-vel.
-
- 11.) Kernel gépek motivációja. Kernel függvények szemléletes tulajdonságaik. Kernel trükk lényege? Kernel, illetve a jellemzőtérbeli ábrázolás kapcsolata (konkrét példákon keresztül).
-
- 12.) Osztályozási célú SVM. Primál kritériumfüggvénye. Ehhez tartozó Lagrange duális függvény. Duális probléma értelmezése, kernel trükk megjelenése. Gyengített SVM motivációja, viselkedésének analízise.
-
- 13.) Regressziós célú SVM alapötlete, primál / duál kritériumfüggvénye. SVM-ek, mint bázisfüggvényes hálók RBF-el, valamint MLP-vel történő összehasonlítása. Gyengítés motivációja, regressziós célú SVM viselkedésének analízise.
-
- 14.) Statisztikus tanuláselmélet kérdései. Torzítás – variancia dilemma (négyzetes Loss fgv. esetén). Mi a túltanulás / alul-illeszkedés? Mi a kockázat, mi az empirikus kockázat? Mi az ERM lényege, mi a VC dimenzió, illetve a strukturális kockázatminimalizálás elve?
-
- 15.) Tanulás statisztikai becslésként történő értelmezése. Frekventista (maximum likelihood) megközelítés lényege. Nevezetes loss fgv-ek (négyzetes, abszolút hiba, kereszt entrópia), és a hozzájuk kapcsolódó zajeloszlások.
-

16.) Regularizáció alkalmazása neurális hálózatok konstrukciója során. Maximum a posteriori (Bayes) becslés, illetve a Bayes-i modellátlagolás lényege. Nevezetes regularizációs függvények (L_2^2 , L_1 , L_2 , L_0) hatásának analízise.

17.) Dinamikus / szekvenciális hálók: Időfüggés megvalósíthatóságának lehetőségei (NFIR, NARX, NOE, NARMAX modellosztály). Modell fokszámának megválasztása (Lipschitz index, maradék hiba auto / keresztkorrelációja alapján).

18.) Véges impulzusválaszú (FIR) MLP konstrukciója. Időbeli kiterítés (BPTT), illetve temporális hiba-visszaterjesztés (TBP) eljárások működése, összehasonlítása.

19.) Visszacsatolt neurális hálózatok konstrukciója. Tanításuk kiterítéssel (BPTT), illetve valós időben (RTRL). A két eljárás értelmezése, viselkedésének analízise és összehasonlítása.

20.) Cella alapú szekvenciális hálózatok (SISO, SIMO, MISO, MIMO). Tanításuk (és annak problémái). Echo State Network (ESN) alapötlete. LSTM, GRU cella felépítése. Hasonlítsa össze az LSTM tanítását, működését más cella alapú szekvenciális hálókkal!

21.) Természetes nyelvű szövegfeldolgozás (NLP) problémája. Bidirekcionális visszacsatolt cella felépítése, motivációja. Klasszikus Seq2Seq megközelítés korlátjai, Attention, Self Attention motivációja, működése. Transformer network alapötlete.

22.) Mély neurális hálók motivációja. Konstrukciójuk, illetve tanításuk nehézségei. Új architektúráis elemeik. Ezek működése, illetve motivációja.

23.) Mély neurális hálók tanításának sajátosságai. Inicializáció, adat előfeldolgozás kérdései. Transfer learning, valamint data augmentation lényege. Milyen optimalizációs módszereket érdemes tanításuk során alkalmazni? Miért?

24.) Konvolúciós neurális hálók architektúráis elemei (konvolúciós réteg, pooling réteg, transzponált konvolúció, szeparábilis konvolúció, up-pooling). CNN-ek általános felépítése, viselkedésük főbb jellemzői. Összehasonlításuk teljesen összekötött neurális hálókkal.

23.) Képszegmentálás, objektum detektálás megvalósítása CNN-el (pixel szintű szegmentálás, objektum lokalizáció + osztályozás, objektumok szegmentálása) U-net, R-CNN, Fast R-CNN, Faster R-CNN, Yolo, RetinaNet hálók / eljárások működése, motivációja.

24.) Ismertebb CNN hálók (AlexNet, VGG, GoogleNet (Inception), ResNet, Stochastic Depth, DenseNet, SENet) architektúráis sajátosságai, ezek motivációja. Neurális paradigmán belül a bizonytalanság becslés lehetősége (szakértő együttesekkel, MC dropout).

25.) Autoenkóder hálók felépítése, fő motivációjuk. Eloszlások mintákból történő tanulásának módszerei, ezen eloszlások mintavételezése: teljes faktorizáció (RNN), variációs autoenkóder (költségfüggvénye, felépítése), GAN-ok alapötlete.
