

## Gépi tanulás vizsga

2018/19. őszi félév

### Tudnivalók:

Azokon a napokon, ahova ötnél többen jelentkeztek, két turnusban lesz a vizsgáztatás (8 és 10 órától). Ha valaki **mindenképpen** szeretne a korábbi/későbbi turnusba kerülni, legkésőbb előző nap délig küldjön levelet a [bolgar@mit.bme.hu](mailto:bolgar@mit.bme.hu) címre, utána véglegesítem a beosztást.

A vizsga során semmilyen segédeszköz nem használható. A vizsga szóbeli, két tételt kell kidolgozni, és – nem feltétlenül a tételekhez kapcsolódó – kérdésekre válaszolni. Az érdemjegyre beleszámítanak a jegyzőkönyvekre kapott pontszámok és a szorgalmi feladatok.

### Tételek:

1. **Bayesi valószínűségelméleti alapfogalmak.** Valószínűség, prior, likelihood, posterior. Maximum likelihood (ML), maximum a posteriori (MAP), teljesen bayesi következtetés, modellátlagolás. A teljesen bayesi következtetés nehézségei (példák, mikor van analitikus megoldás). Konjugált priorok (példák, hol használtuk őket).
2. **Gépi tanulási alapfogalmak.** Generatív és diszkriminatív modellek, diszkriminatív függvények a gépi tanulásban (példák). Bias-variancia dekompozíció, alultanulás, túltanulás, regularizáció. Gyakran használt veszteségfüggvények és regularizációs sémák valószínűségelméleti származtatása. Kiértékelés (CV, AUC, AUPR).
3. **Regresszió.** Alapfeladat, a lineáris regresszió valószínűségi modellje, ML és MAP becslés, ezekre az analitikus formulák levezetése, a megoldás menete (gyakorlatról + numerikus szempontok). Teljesen bayesi következtetés (formulák levezetése nélkül). Nem lineáris kiterjesztések: bázisfüggvények alkalmazása, a gyakorlaton vett bázisfüggvények.
4. **Klasszifikáció.** Alapfeladat, a logisztikus regresszió valószínűségi modellje. Perceptron származtatása a Bayes-tétel felhasználásával, ML és MAP becslés, az iteratív formulák levezetése (szigmoid függvény, gradiens), a megoldás menete (gyakorlatról + numerikus szempontok). Nem lineáris kiterjesztések: bázisfüggvények alkalmazása, a gyakorlaton vett bázisfüggvények.
5. **Neurális hálózatok.** MLP architektúra, ML és MAP becslés, a backpropagation algoritmus levezetése. Deep learning modellekben használt aktivációs függvények, a regularizáció módjai. Konvolúciós és visszacsatolt architektúrák, az ezekben használt rétegtípusok, példa alkalmazások.
6. **Optimalizáció DL modellekben.** Az optimalizáció nehézségei, analitikus és numerikus szempontok. Optimalizációs algoritmusok alapelvei (batch, momentum, adaptív learning rate, magasabb rendű módszerek). Nevezetes algoritmusok (SGD, AdaGrad, RMSProp, ADAM).
7. **Variációs módszerek.** Közelítő bayesi következtetés, ELBO+KL dekompozíció, a variációs módszerek alapelvei. BBVI, sztochasztikus gradiens-alapú optimalizáció (variancia-csökkentés nélkül). Reparametrizációs trükk, VAE. Adversarial training ötlete, GAN architektúrák alapelvei.
8. **Kernel gépek.** Alapötlet, a kernel trükk lényege, a gyakorlaton használt kernel függvények. RKHS konstrukciója, a belső szorzat tulajdonságai. Szupportvektor-gép, veszteségfüggvény (hinge loss) és regularizáció. A duális probléma levezetése a Lagrange-módszerrel (alapötlet). Geometriai interpretáció, maximális margó.
9. **Dimenzió-redukció.** Főkomponens-analízis: alapötlet, veszteségfüggvény, minimalizálása a Lagrange-módszerrel. Geometriai interpretáció. Kernel PCA.

10. **EM algoritmus és klaszterezés.** Maximum likelihood becslés nehézségei rejtett változók esetén. Az EM algoritmus levezetése. Gauss keverék-eloszlás, használata klaszterezésben. EM Gauss-keverékekre (az E- és M-lépések származtatásának fő lépései). K-means algoritmus. Spektrális klaszterezés alapötlete, a diszkrét Laplace-operátor tulajdonságai.
11. **MCMC.** Az MCMC módszerek alapelve. Markov-láncok felépítése, tulajdonságai. Az egyensúlyi eloszlás létezésének elégséges feltétele. Metropolis, Metropolis–Hastings algoritmus. Gibbs-mintavétel, konjugált priorok. Példa: bayesi lineáris regresszió Gibbs-mintavétellel (gyakorlatról).
12. **Modellek kombinációja.** Bootstrap, bagging, az átlagos hiba alakulása. Exponenciális loss tulajdonságai, összehasonlítása egyéb veszteségfüggvényekkel. Az exponenciális loss minimalizálása gyenge osztályozók lineáris kombinációjával. Az AdaBoost algoritmus levezetése, magyarázata.
13. **Aktív tanulás.** A  $K$ -karú rabló probléma, exploration vs. exploitation tradeoff. Regret definíciója, ennek alakulása különböző stratégiák esetében. UCB1 algoritmus, a felső korlát bizonyítása.