



Mesterséges intelligencia informatikus MSc (2026) – záróvizsga tételek

A mesterséges intelligencia elméleti háttéréhez kapcsolódó alapismeretek:

1. Lineáris algebrai alapfogalmak a gépi tanuláshoz; mátrixfelbontások (SVD, Cholesky, spektrál); többváltozós differenciálszámítás (gradiens, Jacobian, Hessian); többdimenziós eloszlások, kovariancia; PCA, CCA és MDS elméleti alapjai; statisztikai modellek értékelése, hipotézisvizsgálat, konfidenciaintervallumok, klaszterezés kiértékelése.
2. Többváltozós függvények feltétel nélküli és feltételes szélsőértéke. Gradiens-alapú módszerek (SGD, momentum, Adam stb.); Newton- és kvázi-Newton-eljárások; konvex és nemkonvex optimalizálás; regularizáció; feltételes optimalizálás és büntetőfüggvények; a tanulási dinamika elmélete mély modellekben, legkisebb négyzetek módszere, sztochasztikus optimalizálás.
3. Felügyelt- és nem felügyelt tanulás; Egy és többváltozós lineáris regresszió; Gradiens csökkenési eljárás; Sztochasztikus és mini-batch gradiens csökkentés; Leírók normálása; Polinomiális regresszió; Normál egyenlet; Logisztikus regresszió; Két- és többosztályos osztályozás; Regularizáció (alul- és túltanulás); Regularizált lineáris és logisztikus regresszió;
4. Perceptron-tétel; MLP architektúrák és tanítás; backpropagation; aktivációs és veszteségfüggvények; eltűnő és robbanó gradiens; CNN-ek felépítése és jelentős architektúrák; RNN, LSTM, GRU elmélete; SVM-ek és kernel-módszerek. Neurális hálók; Backpropagation algoritmus; Numerikus gradiensellenőrzés.
5. Tanító/Teszt/Validációs adatfelbontás; Tanítási diagnosztika; Tanulási görbék (tanító adathalmaz mérete); Hibamérés és kiegyenlített osztályok; Támasztóvektor-gépek és magfüggvények alkalmazása; Klaszterezés; Klaszterek számának meghatározása; Dimenziócsökkentés; Anomáliadetektálás (normális eloszlás); Bagging és Random Forest elmélete, Boosting (AdaBoost, Gradient Boosting); XGBoost működési alapelvei; HDBSCAN és más sűrűség-alapú klaszterezési technikák; magas dimenziójú problémák elméleti kezelése.
6. Transformer-architektúra, attention-mechanizmus; előtanítási paradigmák (MLM, NSP, self-supervised learning); fine-tuning (DPO, RLHF); tokenizálás és embedding-technikák; beszédfelismerő rendszerek (Whisper) elmélete; multimodális modellek.
7. Autoencoder és VAE; GAN-ek és főbb architektúráik; diffúziós modellek elméleti alapjai; transzformer-alapú generatív modellek; feltételes generálás; minőségértékelési mutatók (FID, IS, CLIP-score); etikai és torzítási problémák, Etikus MI és előítéletmentesítés.
8. Elosztott modell-tanítás és kommunikáció; párhuzamos számítási módszerek; felhőalapú MI rendszerek architektúrái; konténerizáció elméleti alapjai (Docker, Kubernetes); MI-pipeline-ok és modellverziózás. MI-szabályozási keretek; adatvédelem, GDPR; biztonságos MI rendszertervezés; modellek sebezhetőségei és támadástípusok.

A mesterséges intelligencia gyakorlati háttéréhez kapcsolódó alapismeretek:

1. Adattisztítás, transzformáció, reprezentáció; valós adathalmazokon végzett exploráció; hibakezelés; adatvizualizáció; gyakorlatban alkalmazott statisztikai diagnosztika. Az adatvizualizáció alapvető fogalmai, kialakulásának története, a vizuális érzékelés szerepe.
2. Regressziós és osztályozási modellek tréningje; cross-validation; teljesítménymutatók (accuracy, precision, recall, ROC-AUC); bias–variance analízis; túl- és alulillesztés kezelése. Random Forest, XGBoost, Gradient Boosting; HDBSCAN alkalmazása; NLP-feladatok megoldása (szövegosztályozás, embedding-kezelés).
3. Prompt-tervezés; finomhangolás (LoRA, DPO, RLHF); QA-rendszerek építése; generatív szövegalkotási feladatok megoldása; beszédfelismerés implementációja (Whisper). Prompt injection, adat- és modellkiszivárgás, modell-lopás szimulációja.
4. Autoencoder, VAE, GAN és diffúziós modellek tréningje; képgenerálás; adat-augmentáció; minőségértékelés Kép- és szöveggenerálás, adat-augmentáció, stílusátvitel, diffúziós modellek futtatása, GAN-alapú feladatok, generált tartalom minőségértékelése (FID, IS, CLIP-score).
5. Grad-CAM vizualizáció CNN-ekben. Attention mechanizmusok magyarázata transformer modellekben. Konfidenciaintervallumok, próbák, újra mintavételezés gyakorlati alkalmazása. Osztályozók összehasonlítása ROC, AUC, Brier-score, kalibráció alapján. Klaszterezési megoldások gyakorlati értékelése (stabilitás, indexek).
6. Valós ipari probléma modellezése és MI-alapú megoldása. Modellválasztás, optimalizálás, dokumentálás. Modellméret-csökkentési technikák: pruning, quantization. Gyorsítási megoldások (knowledge distillation, tensor optimalizáció).
7. A felhőkörnyezet megbízhatóságának, rendelkezésre állásának, skálázhatóságának ismertetése; A felhős alkalmazások és rendszerek költségeinek bemutatása, elemzése; A felhős környezetben a rendelkezésre állási mérőszámok ismertetése;
8. Mesterséges intelligencia (MI) programozásához kapcsolódó függvénykönyvtárak; Kernel szintű futtató és fordító környezetek; Elterjedtebb függvénykönyvtárak, eszközök (scikit-learn, NumPy, SciPy, pandas, Jupyter, Matplotlib, Dataflow, Keras, TensorFlow).