

## Otázky na záverečnú skúšku - Neurónové siete

1. Stručná história konekcionizmu, vlastnosti biologického neurónu, model neurónu s prahovou logikou, implementácia Booleových funkcií. Paradigmy učenia a typy úloh pre NS.
2. Binárny perceptrón: pojem učenia s učiteľom, učiace pravidlo, algoritmus tréovania, deliaca nadrovina, klasifikácia vzorov, lineárna separovateľnosť, náčrt dôkazu konvergenencie, definícia a príklad.
3. Spojitý perceptrón: Rôzne aktivačné funkcie perceptrónu, chybové funkcie a spôsob minimalizácie, učiace pravidlá, algoritmus tréovania perceptrónu. Súvis s Bayesovským klasifikátorom.
4. Viacvrstvové dopredné neurónové siete: architektúra a aktivačné vzorce, odvodenie metódy učenia pomocou spätného šírenia chýb (BP) pre dvojvrstvovú doprednú NS, typy úloh pre použitie doprednej NS.
5. Viacvrstvová dopredná NS ako univerzálny aproximátor funkcií (teorém), tréovacia a testovacia množina, generalizácia, preučenie, selekcia modelu, validácia modelu, bias-variance tradeoff.
6. Modifikácie gradientových metód učenia, Hessián, hlboké učenie: aktivačné funkcie, inicializácia siete, predtréovanie, základné modely, regularizácia.
7. Lineárne modely NS: vzťah pre riešenie systému lin. rovníc v jednovrstvovej sieti, pojem pseudoinverzie matice (Moore-Penrose), autoasociatívna pamäť: lineárny obal, princíp funkcie modelu, detektor novosti.
8. Lineárne modely NS: účel Grammovho-Schmidtovho ortogonalizačného procesu, GI model. Pamäť korelačnej matice ako autoasociatívna pamäť, vzťah pre výpočet váh, presluch, porovnanie s GI.
9. Samoorganizácia v NS, základné princípy, pojem učenia bez učiteľa, typy úloh použitia, Ojovo pravidlo učenia pre jeden lineárny neurón, vysvetlenie konvergenencie.
10. Metóda hlavných komponentov pomocou algoritmu GHA a APEX, architektúra modelu, vzťah pre adaptáciu váh, pojem vlastných vektorov a vlastných čísel, redukcia dimenzie, aplikácia na kompresiu obrazu.
11. SOM model: algoritmus, parametre, základné koncepty, vlastnosti, príklad použitia.
12. RBF model: aktivačné vzorce, bázové funkcie, príznakový priestor, problém interpolácie, tréovanie modelu, aproximačné vlastnosti RBF siete, princíp algoritmu RLS.
13. NS na spracovanie sekvenčných dát: reprezentácia času, typy úloh pre rekurentné NS. Modely s časovým oknom do minulosti, výhody a nedostatky, príklad použitia.
14. Rekurentné NS: princíp tréovania pomocou algoritmov BPTT a RTRL. Teoretické vlastnosti RNS. Model RecSOM.
15. Elmanova sieť: interné reprezentácie pri symbolovej dynamike, Markovovské správanie, architekturná predispozícia.
16. Sieť s echo stavmi (ESN): architektúra, inicializácia, tréovanie modelu, vplyv parametrov na vlastnosti rezervoára, echo vlastnosť, pamäťová kapacita.
17. Hopfieldov model NS: deterministická dynamika, energia systému, relaxácia, typy atraktorov, autoasociatívna pamäť – nastavenie váh, princíp výpočtu kapacity pamäte.
18. Nelineárne dynamické systémy: stavový portrét, dynamika, typy atraktorov. Stochastický Hopfieldov model NS: parameter inverznej teploty, princíp odstránenia falošných atraktorov.
19. Stochastické modely: základné koncepty teórie pravdepodobnosti a štatistickej mechaniky, Boltzmannov stroj, RBM, Deep Belief Network – architektúry, tréovanie.
20. Wild card :-)