

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, 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. Viacvrstvé dopredné neurónové siete: architektúra, učenie pomocou spätného šírenia chýb (BP), typy úloh pre použitie doprednej NS.
5. Viacvrstvá 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: asociácia vzorov, pojem pseudoinverzie matice (Moore-Penrose), autoasociatívna pamäť: princíp funkcie modelu General Inverse, lineárny obal, G-S ortgonalizácia, detektor novosti.
8. Samoorganizácia v NS, základné princípy, pojem učenia bez učiteľa, typy úloh použitia, Ojovo pravidlo učenia pre jeden lineárny neurón, vysvetlenie konvergencie.
9. Metóda hlavných komponentov (PCA): implementácia pomocou jedného neurónu, algoritmus GHA, architektúra modelu, učenie, vlastné vektory a vlastné čísla, redukcia dimenzie, aplikácia na kompresiu obrazu.
10. SOM model: algoritmus, parametre, základné koncepty, vlastnosti, príklad použitia.
11. RBF model: aktivačné vzorce, bazové funkcie, príznakový priestor, problém interpolácie, tréovanie modelu, aproximačné vlastnosti RBF siete, princíp algoritmu RLS.
12. Základy hlbokého učenia: inicializácia parametrov, aktivačné funkcie, regularizácia, tréovanie. Konvolučné neurónové siete: základné pojmy (operácie), invariantnosť.
13. NS na spracovanie sekvenčných dát: reprezentácia času, typy úloh pre rekurentné NS. Modely s časovým oknom do minulosti, výhody a nedostatky. Princíp algoritmov BPTT a RTRL.
14. Elmanova sieť: interné reprezentácie pri symbolovej dynamike, Markovovské správanie, architekturná predispozícia. Vzťah RNN ku n-gramom.
15. Sieť s echo stavmi (ESN): architektúra, inicializácia, tréovanie modelu, vplyv parametrov na vlastnosti rezervoára, echo vlastnosť, pamäťová kapacita.
16. Autoenkóдеры: základné koncepty, tréovanie. Moderné RNN: modely GRU, LSTM – princíp funkcie.
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 :-)