

#	Kérdés	I/H	Indoklás / válasz
1	A bias-variance dilemma a neurális háló és a tanuló halmaz mérete közötti ellentmondást fejezi ki.	I	either minimizing the first term (which is referred to as bias) with a relatively large size network, but in this case with a limited size training set the weights cannot be trained correctly by learning, so the second term will be large
2	A generalizációs képesség a Hopfield háló energiafüggvényének a szerkezetére utal. A VC dimenzió határozza meg a tanulóhalmaz hosszát, ha a megoldást adott minőségben szeretnénk megtanulni.	H	VC: Defined as the cardinality of the largest set of points that the algorithm can shatter.
3	A Hebbi tanulási szabály a Hopfield hálózat összeköttetéseinak a számát adja meg a tárolni kívánt vektorok függvényében.	H	A Hebbi tanulási szabály a Hopfield neuronjainak $W$ paraméterét adja meg a tárolni kívánt vektorok függvényében. $b=0$
4	A Hopfield hálóknak vannak fixpontjai.	I	$SI = \text{sgn}(\text{SUM}(W_{ij} * S_j)) \quad j=1 \dots N$
5	A Hopfield háló tetszőlegesen választott tárolt memóriavektorok esetén is eléri az elvi kapacitás korlátot.	H	A mintáknak ortogonálisnak kell lenniük.
6	Előrecsatolt neurális hálózatok esetén a Vapnik-Chernovenkis dimenzió a súlyok számával lineárisan növekszik.	H	négyzetesen vagy sigmoid esetén ( $W * I_{GW}$ )
7	A TSP optimális megoldását a Hopfield hálózat nem minden esetben találja meg.	I	Az optimális megoldáshoz mindig a globális minimumot kéne eltalálni, ezzel szemben a HNN egy lokális minimumhoz konvergál, ami nem feltétlenül esik egybe a globálissal.
8	A XOR logikai függvény megvalósítható 2 perceptronnal.	I	Volt rá feladat egy 2 és egy 3 bemenetűvel valósítható meg.
9	A Hopfield hálózatok dinamikus kapacitása ortogonális memóriavektorok esetén nagyobb, mint véletlen generált memóriavektorok esetén.	I	$M < (N^2 / (N-2)^2) \lll M < N/2PI$
10	Az előrecsatolt neurális hálózatok tetszőleges osztályból származó függvényt képesek approximálni.	H	Csak L2 függvényosztályból származóakat.
11	A tanulóhalmaz felett felírható empirikus hibafüggvény egyenletesen konvergál a teoretikus hibafüggvényhez a mintaszám növelesével.	H	Bias-Variance dilemma
12	Egy CNN tömb esetén a neuronok közötti kapcsolatokat leíró súlymátrix ritkás kitöltésű.	I	Ritkás kitöltésű, lásd péda.
13	Egy 2 bemenetű perceptronon 14 különböző logikai függvényt lehet implementálni.	I	$2^2 - 2 = 14$
	A Hopfield hálózatok statikus kapacitása ortogonális memóriavektorok esetén kisebb, mint véletlen generált memóriavektorok esetén.	H	$N < N/2 \lg N$ $N = 1, 2, 3$ ra igaz felette hamis
14	Az előrecsatolt neurális hálózatok tanítása a perceptron tanítási szabály alapján is lehetséges, ha a hálózat egy bemeneti, egy rejtett és egy kimeneti réteget tartalmaz.	H	The Rosenblatt algorithm is inapplicable, while we do not know the error and desired output in the hidden layers of the FFNN
	Egy erősen görbült célfüggvény approximációja esetén a hálózat bonyolultságának növelesével pontosabb közelítést érünk el a tanulóhalmaz mintái alapján.	I	Volt rá péda, de nem vagyok biztos benne, hogy ez akármeddig fokozva is igaz.
15	Egy CNN tömb esetén, ha a szomszédossági sugárra igaz, hogy $r=3$ , akkor az A template matrix $6 \times 6$ -os mátrix.	H	$7 \times 7$ -es
16	Egy Hopfield hálózatnak $N^2$ szabad paramétere van.	H	Egy neuronnak van $2^2 \times N$ db, de ebből nem mind megvalósítható.
17	A perceptron tanulás konvergencia sebességére felírható felső becslés függ a szeparálást megoldó súlyvektor normájától.	I/H	$<= 4kM^2$
18	Egy $10 \times 10$ -s CNN processzortömb $r=2$ lokális sugár esetén kevesebb, mint ötöd annyi összeköttetést tartalmaz, mint egy azonos neuronszámú Hopfield hálózat. Hopfield hálózatokban aszinkron állapotátmenet esetén, ha a neuronok véletlen sorrendben változthatják állapotukat, bizonyos esetekben a hálózat nem konvergál, és határciklusba kerül.		
19	A LEGO elv a többretegu hálózatok tanulási képességéről szól.	H	A LEGO-elv lényege az, hogy egyszerű elemekből építünk bonyolult rendszert, és nem az építőelemek, hanem a kapcsolatrendszer adja a hálózat intelligenciáját.
20	Egy $\text{sgn}()$ küszöbfüggvénnyel rendelkező neuron tetszőlegesen nemlineáris halmazszeparálásra képes	H	$N$ dim hipersíkkal képes szeparálni a teret.
21	Egy neuron küszöbfüggvénye nem korlátos függvény	H	Nem-lineáris, korlátos függvény.
22	Egy neuron az elemi számítások során a bemenetek súlyozott összegét is képezi	I	$y = \text{sgn}(\text{SUM}(W_i * x_i - b_i))$
23	A Hopfield hálóban nincs visszacsatolás	H	A Hopfield-net-ben az összes neuron vissza van csatolva az összes neuronra.
24	A diszkrét Hopfield háló állapotvektorai bináris vektorok $\text{sgn}()$ küszöbfüggvények esetén	?	Abból a tekintetben bináris, hogy csak két értéket, -1 és 1-et vehet fel, de nem 0 és 1-et. Végülis igazként is lehet értelmezni az állítást.
25	Az állapotvektor frissítését csak szekvenciális módon lehet végrehajtani	H	Nem, létezik paralell állapotátmeneti-szabály is. Viszont erre a konvergenciát nem bizonyítottuk.
26	A Hopfield háló energia- (Lyapunov) függvénye egy kvadratikussal alak	I	Ez igaz, mert az egy homogén többhatározatlanú másodfokú polinom az állapotvektor, a biasvektor és a súlymátrix függvényében.
27	A Hopfield háló az energiafüggvénynek mindig a globális extrémumába konvergál	H	Hamis, egy lokális extrémumba konvergál, ami nem minden esetben egyezik meg a globálissal (extrémum == szélsőérték).
28	A diszkrét Hopfield háló konvergenciája a dimenzió függvényében exponenciális lépésszámot igényel		
29	A Hebbi tanulási szabály a Hopfield hálózat súlymátrixát adja meg a tárolni kívánt vektorok függvényében	I	A súlymátrixát és a bias vektorát is, tehát akár hamis is lehet az állítás. :)
30	Csak ortogonális vektorhalmaz esetén lehetnek a tárolni kívánt vektorok a Hopfield háló fixpontjai	I	igaz ez a HNN kritériuma ?

31	A fixpontok egyúttal az energiafüggvény extrémumainál vannak				
32	A Hopfield háló polinomiális időben ad asszociatív leképezést	I			
33	Az $O(N/2 \log N)$ kapacitás csak akkor érhető el, ha véletlenszerűen sorsoljuk a tárolni kívánt memóriavektor komponenseit	H	Nem kell feltétlenül véletlenül sorsolni, lényeg az, hogy kvázi-ortogonális vektorokat tároljunk.		
34	Egy tárolt memóriaelemre nemcsak a fixpontkritérium, hanem a stabilitást is fenn kell, hogy álljon	I	Sztem ez igaz, különben nem lesz megbízható a HNN.		
35	A Hopfield hálónál a minimalizáláshoz negatív diagonálemekre van szükség	H	Diagonált nullázzuk.		
36	A súlymátrix módosításával mindig elérhető, hogy a globális minimumot keresse meg a hálózat	H	A közbüggvénnyel érhető el és ezzel is csak a lokális minimum biztosított.		
37	Az N csomópontból álló gráfon a Hopfield háló $N^4$ lépésszámban talál optimális hurkot.				
38	Hibajavító dekódolásnál a Hopfield háló tárolt memóriavektorai a csatorna torzítások	H	A detektálni kívánt jelvektorokat tároljuk. Ezekhez adódik a hiba és ezt javítja a HNN.		
39	Az optimális hurokkeresés Hopfield hálózattal való megoldásánál a célfüggvény tisztán a minimális távolságot fejezi ki.				
40	Optimális hurokkeresés esetén elég a Hopfield algoritmust egyszer lefuttatni.				
41	Az előrecsatolt neurális háló egymásbaskatulyázott függvényekkel írható le.	I	Igaz, a rétegek kimeneteit ágyazzuk a következő réteg bemenetébe.		
42	Az előrecsatolt neurális háló csak lineáris függvényeket képesek approximálni	H	Bármely L2 fv-osztály-beli függvényt képesek közelíteni.		
43	Kétrétegű neurális hálókkal tetszőleges lépcsős függvényeket elő lehet állítani				
44	A back-propagation algoritmus a hiba gradiensét használja a súlyok beállításra	I	gradiens mentén a negatív irányba mozdítja el a súlyokat		
45	A back-propagation algoritmus mindig megtalálja a hiba globális minimumát	H	de lokális minimum elérhető		
46	A back-propagation algoritmust csak on-line lehet lefuttatni (minden egyes tanulóhalmabeli pár lapján vegzünk egy iterációt)				
47	A nagy előrecsatolt hálózat méret jó az approximációs hiba csökkentéséhez, de növekszik a tanulási komplexitása	I	ezt hívják Bias-Variance dilemmának		
48	A generalizációs képesség az approximációs hiba mértékéről ad felvilágosítást	I	Hiszen az approximációs hibát a kívánt kimenet és a FFNN kimenetének a négyzete határozza meg, melynek a nagysága a generalizációs képességet mutatja. Vagy valami ilyesmi sztem.		
49	Ha a tanulóhalmaz mérete tart a végtelenhez, akkor aszimptotikusan teljes bemeneti ter felett definált hibát sikerül minimalizálnunk.				
50	A perceptron tanulási szabályban elvileg végtelen ideig tart az optimális súlyok meghatározása.	I	Elvileg igen, de ha az állapot vektor a tanulás során N lépésszámig nem változik, befejezhetjük a tanítást.		
51	Egy kétrétegű neurális hálóval minden halmazszeparálás közelíthető.				
52	Egy neuronnak csak pozitív súlyai lehetnek.	H	Erre nincs megkötés.		
53	A Hopfield hálóban szekvenciális állapotátmeneti szabály esetén egyszerre mindig csak egy neuron állapota változik.	I	Ezért szekvenciális.		
54	A diskret Hopfield háló egy véges állapotú automata.	I	Igaz, véges számú különböző állapotvektora lehet.		
55	A Hopfield analóg implementációjában nincs energiatároló tag.	?H	Szerintem pont, hogy van. De nem vagyok benne biztos, hogy tudom, hogy mi az az energiatároló tag		
56	A Hopfield háló energia- (Lyapunov) függvényének mindig csak egy optimuma van.				
57	A Hopfield háló az energiafüggvényben mindkét irányban (növekvő és csökkenő) is elmozdulhat.	H	Ez hamis szerintem, mindig csak egy irányba megy, így találja meg a lokális szélsőértéket.		
59	Az analóg Hopfield háló szintén az energiafüggvény extrémumaiba konvergál.	I	Ezt nem tanultuk, de nyilván igen.		
60	A Hebb tanulási szabály a Hopfield hálózat összeköttetéseiinek a számát adja meg a tárolni kívánt vektorok függvényében.	H	A Hebb tanulási szabály a súlymátrixot és a bias-vektort adja meg a tárolni kívánt vektorok fv-ében.		
61	A Hopfield hálónak nincsenek fixpontjai.	H	Vannak. $SI = \text{sgn}(\sum (W_{ij} * S_j))$ $j=1 \dots N$		
62	A Hopfield háló tetszőlegesen választott tárolt memóriavektorok esetén is eléri az elvi kapacitás korlátot.	H	Mintáknak ortogonálisnak kell lenniük.		
63	A Hopfield háló nem polinomiális időben ad asszociatív leképezést, hanem $O(N^2)$ .	H	$N^2$ az polinomiális idő...		
65	A Hopfield hálónál a minimalizáláshoz nulla diagonál elemekre van szükség.	I	És emellett -sgn-ra, ezzel bizonyítottuk, hogy a Lyapunov függvény konvergálni fog egy lokális minimumba.		
66	A közbüggvény módosításával mindig elérhető, hogy a globális minimumot keresse meg a hálózat.	H	Csak a lokális szélsőérték megtalálása biztosított.		
67	Az N csomópontból álló gráfon a Hopfield háló $\log(N)$ lépésszámban talál optimális hurkot.				
68	Hibajavító dekódolásnál a Hopfield háló tárolt memóriavektorai a kódszavak.	H?	A kódszavakhoz választott ortogonális jelek. Melyekből LUT állítja vissza a kódszavakat.		
69	Az optimális hurokkeresés Hopfield hálózattal való megoldásánál a célfüggvénybe kényszereket kell bevonni, hogy utvonál szempontjából érvényes megoldást kapjunk.	I			
71	Az utazó ügynök problémánál a Hopfield algoritmus biztosan a legjobb megoldást adja.	H	Nem, mivel lokális szélsőértékbe konvergál globális helyett, emiatt nem mindig az optimális megoldást adja.		
72	Az előrecsatolt neurális hálónál stabilitási problémák lépnek fel.	H			

73	Az előrecsatolt neurális hálók minden négyzetesen integrálható függvényt képesek approximalni.	I	Igaz, ez az L2 fv-ek tere.		
74	Kétrétegű neurális hálókkal tetszőleges lépcsős függvényeket elő lehet állítani.	I			
75	A back-propagation algoritmusnál a hiba visszaterjed a kimenetről a belső rétegek fele.	I	Ezért BP.		
76	A back-propagation algoritmus csak lokális minimumokat talál meg.	I			
77	A back propagation algoritmusnak van off-line verziója is.	?			
78	A bias-variance dilemma a neurális háló mérete és a tanulás bonyolultsága közötti ellentmondást fejezi ki.	I	Bias: approximation error; Variance: learning error; FFNN nagy->min Bias, nagy Variance és vice versa		
79	A generalizációs képesség a Hopfield háló energiafüggvénynek szerkezetére utal.				
80	A VC dimenzió határozza meg a tanulóhalmaz hosszát, ha a megoldást adott minőségben szeretnénk megtanulni.	I	fűzetben. 7.ea: design procedure		
81	A Hebbi tanulás nyomán kapott súlymátrix csak bináris lehet.	H	1/N szorzó miatt ez biztosan nem igaz.		
82	Ha a tárolni kívánt bináris vektorok ortogonálisak, akkor a súlymátrix diagonális.				
83	A bias vektort (b) mindig a legutolsó tárolt minta szerint kell beállítani.	H	Ez egy abszolút valótlan állítás. Milyen esetben? Hebbi-nél a b=0		