

# Využitie neurónových sietí vo vesmíre

Milan Tkáčik

Katedra kybernetiky a umelej inteligencie  
Technická univerzita v Košiciach  
Košice, Slovenská republika  
milan.tkacik@student.tuke.sk

**Abstrakt**—V posledných desaťročiach sa umelé neurónové siete stále viac a viac rozširujú do vedeckých odborov skúmajúcich vesmír, ako sú astronómia a astrofyzika. Technický pokrok v oblasti digitálnej fototechniky, rozvoja optických teleskopov a rádioteleskopov, či už pozemných alebo orbitálnych, zapríčinil prúdenie obrovského množstva dát určeného na spracovanie. Kvôli veľkému množstvu dát spracovanie človekom nepripadá v úvahu, ale spracovávajú sa v počítačoch. Bežné prístupy často nevedia vyriešiť úlohy, s ktorými človek nemá žiaden problém. Preto boli zavedené metódy využívajúce neurónové siete. Medzi najčastejšie aplikácie neurónových sietí v astrofyzike patrí klasifikácia vesmírnych objektov, identifikácia a oddelenie šumov od signálu alebo hĺbková analýza dát.

**Keywords**—neurónové siete, astrofyzika, galaxie, hviezdy

## I. ÚVOD

Vesmír fascinoval ľudí už od nepamäti, len spôsob jeho pozorovania sa postupne menil. Od staroveku kedy ho ľudia pozorovali len voľným okom, cez stredovek kedy Galileo Galilei prvý krát otočil ďalekohľad na oblohu až po súčasné teleskopy umiestnené na obežnej dráhe Zeme. Každým týmto obdobím narastalo množstvo získavaných informácií, až to množstvo dalo ľuďom nádej na spracovanie. Danú situáciu vyriešil až rozvoj počítačov a algoritmov umelej inteligencie, ako sú neurónové siete.


## II. NEURÓNOVÉ SIEŤE

Umelá neurónová sieť je veľmi zjednodušený výpočtový model funkcionality biologického mozgu. Aj keď je princíp fungovania neurónovej siete veľmi podobný princípu fungovania ľudského mozgu, jej účinnosť je rádovo nižšia, keďže ani s dnešnými technickými prostriedkami nie je možné dosiahnuť, ani sa priblížiť zložitosti ľudského mozgu. Jedná sa v podstate paralelný procesor, ktorý si znalosti získané počas fázy učenia uchováva v medzineurónových spojeniach, tzv. synaptických váhach.

Elementárnou jednotkou neurónovej siete je neurón. Ten má  $n$  vstupov, kde každému vstupu je priradená určitá synaptická váha. Výstup neurónu, teda jeho aktivácia, je daný výsledkom aktivačnej funkcie, ktorej vstupom je súčet (v niektorých prípadoch súčin) vstupov do neurónu vynásobených príslušnými váhami. Keďže sa jedná o učiaci systém, tak na základe rozdielu očakávaného výsledku a získaného výsledku, alebo na základe hodnoty nejakej


cenovej hodnotiacej funkcie sa upravujú synaptické váhy vstupov daného neurónu.

Ak daný systém obsahuje práve jeden neurón, jedná sa o tzv. perceptrón. Perceptrón je schopný len dichotomickej klasifikácie za predpokladu, že príznakový priestor (vstupný priestor) je lineárne rozdeliteľný. Z toho dôvodu je pre riešenie zložitejších problémov nutné použiť masívnejšiu neurónovú sieť. Tá sa väčšinou skladá z jednej vstupnej vrstvy, jednej výstupnej vrstvy a žiadnej alebo niekoľkých skrytých vrstiev. Topológia danej siete predurčuje jej schopnosť a rýchlosť naučiť sa daný problém.



Obr. 1 – Perceptrón

Spôsob činnosti neurónovej siete nezávisí len od jej topológie, ale aj od spôsobu jej učenia. Pri probléme klasifikácie sa využíva kontrolované učenie, najčastejšie metóda spätného šírenia chyby (backpropagation), kde sa snažíme neurónovú sieť naučiť zaradiť objekt do jeho triedy. Pri nesprávnom zaradení objektu do triedy sa chyba spätne šíri neurónovou sieťou, pričom sa počas šírenia tejto chyby upravujú synaptické váhy medzi vrstvami danej neurónovej siete. Problém zhlukovania využíva metódu nekontrolovaného učenia, kde sa neurónová sieť snaží minimalizovať nejakú cenovú funkciu a na základe toho vytvorí zhluky objektov s podobnými vlastnosťami.



Obr. 2 – Dopredná neurónová sieť

### III. APLIKÁCIE NEURÓNOVÝCH SIETÍ V ASTRONÓMII A ASTROFYZIKE


#### A. Separácia hviezd od galaxií

Základným problémom spracovania snímok oblohy počítačom je rozlíšenie hviezd od galaxií, keďže vzdialená galaxia sa môže veľmi podobat' na hviezdu. Na riešenie tohto problému sa používa neurónová sieť so spätným šírením chyby, ktorá dokáže rozlíšiť hviezdy od galaxií na základe ich fotometrických vlastností.

Experimentálne sa zistilo (Odewahn & Nielsen, 1994), že najlepšie výsledky boli dosiahnuté pri použití neurónovej siete so vstupnou vrstvou zloženou zo siedmich fotometrických vlastností objektu, dvoma skrytými vrstvami a výstupnou vrstvou zloženou z dvoch tried (trieda hviezda, trieda ne-hviezda). S rastúcimi rozmermi skrytých vrstiev sa dĺžka učenia siete lineárne predlžovala, čiže je lepšie použiť menší rozmer skrytých vrstiev, pokiaľ je neurónová sieť schopná naučiť sa daný problém. Pri testovaní táto neurónová sieť dosahovala 90% úspešnosť klasifikácie hviezd od galaxií.

#### B. Morfológická klasifikácia galaxií

Morfológický typ galaxie opisuje jej vzhľad a zároveň poskytuje užitočné informácie o jej štruktúre a histórii. Jedná sa o Hubbleovu klasifikáciu galaxií, kde *E* značí eliptickú galaxiu, *SO* šošovkovú galaxiu, *Sx* špirálovú galaxiu a *Irr* nepravidelnú galaxiu.



Obr. 3 – Hubbleova klasifikácia galaxií

Pre túto klasifikáciu bola použitá (Storrie-Lombardi, Lahav & Sodre, 1992) neurónová sieť so spätným šírením chyby. Vstupná vrstva pozostávala z trinástich neurónov, kde každý neurón reprezentuje jeden parameter galaxie. Neurónová sieť má taktiež jednu skrytú vrstvu a výstupnú vrstvu pozostávajúcu z piatich tried. Konkrétne sa jedná o Hubbleove triedy galaxií *E*, *SO*, *Sa* + *Sb*, *Sc* + *Sd* a *Irr*.


Finálna reprezentatívna vzorka dát obsahovala 5217 galaxií, ktoré boli náhodne zamiešané a rozdelené na trénovaciu a testovaciu vzorku (1700 prvkov pre trénovaciu vzorku, 3517 prvkov pre testovaciu vzorku). Vstupné parametre všetkých prvkov boli normalizované do intervalu od 0 po 1 na základe maximálnej a minimálnej hodnoty každého parametra.

Výsledky získané na testovacej množine dosahovali 64% úspešnosť klasifikácie, zatiaľ čo výsledky získané algoritmom ESO AUTO dosahovali o 8% nižšiu úspešnosť. Z toho vyplýva, že pre morfológickú klasifikáciu galaxií je možné použiť neurónovú sieť, avšak stále má veľké nedostatky oproti klasifikácii človekom.

#### C. Spektrálna klasifikácia hviezd

Spektrálna klasifikácia hviezd sa určuje podľa teploty hviezd. Keďže teplotu fotosféry nie je možné priamo zmerať, musí sa využiť nepriamy princíp. Svetlo dopadajúce z hviezd sa štrbinovým spektrografom rozloží na svoje spektrum a na základe intenzity a rozmiestnenia absorpčných čiar sa určí teplota, následne aj spektrálna trieda.

Podľa spektrálnej klasifikácie hviezd rozdeľujeme do siedmich hlavných skupín: *O*, *B*, *A*, *F*, *G*, *K*, *M*, kde *O* označuje najteplejšie hviezdy (viac ako 30000K) a *M* označuje najchladnejšie hviezdy (menej ako 3700K). Zároveň dané triedy určujú dohodnuté farby hviezd, a to: *O* – modrá, *B* – modro-biela, *A* – biela, *F* – žltá-biela, *G* – žltá, *K* – oranžová, *M* – červená. V súčasnej klasifikácii (Morgan-Keenanovej spektrálnej klasifikácii) sa spektrálna trieda rozširuje aj o číslo v rozsahu od 0 do 9, ktoré označuje desatinu rozsahu medzi hlavnými triedami. Medzi veličiny klasifikácie hviezd patrí ešte aj svietivosť triedy, teda šírka určitej absorpčnej čiary hviezdneho spektra, ktorá sa vyjadruje rímskymi číslicami od I do V.



Obr. 4 – Hertzsprung-Russelov diagram

Z toho vyplýva, že pri hviezdnej klasifikácii je možné naraziť na 350 rôznych hviezdnych tried, ale keďže uvažujeme len spektrum v rozsahu od 3510 Å do 8930 Å s rozlíšením 11 Å, uvažujeme len 72 rôznych reálne sa vyskytujúcich hviezdnych tried.

Pre túto spektrálnu klasifikáciu sa využíva neurónová sieť so spätným šírením chyby, kde trénovacie dáta sú usporiadaná množina daných 72 tried (výstup neurónovej siete) a jednotlivé absorpčné spektrálne čiary (vstupy neurónovej siete).

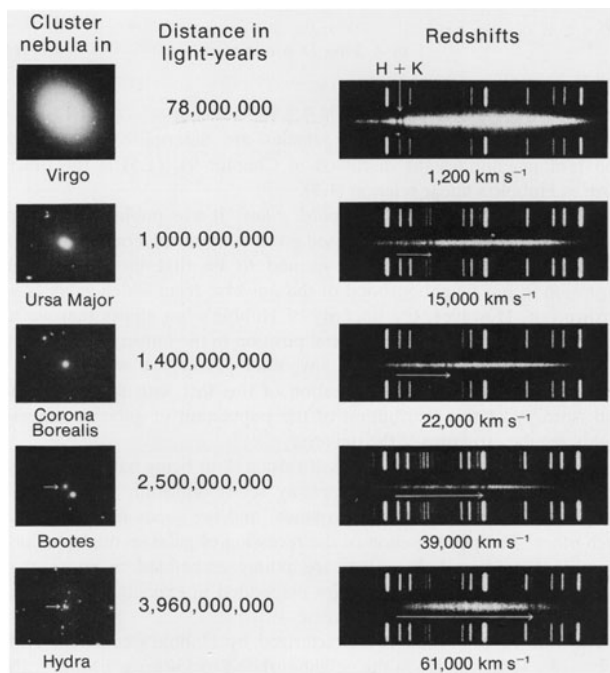
Keďže príznakový priestor je rádovo niekoľko sto rozmerný, tréningovanie aj používanie danej neurónovej siete je výpočtovo veľmi náročné. Preto je užitočné na základe tohto príznakového priestoru vytvoriť nový, rádovo menší príznakový priestor, ktorý si zachová všetky informácie potrebné pre správnu klasifikáciu danej hviezdnej triedy.

#### D. Fotometrický červený posun galaxií

Vlnový charakter svetla zapríčiňuje predlžovanie vlnovej dĺžky svetla šíriaceho sa od objektu ktorý sa relatívne vzdaluje od pozorovateľa. Tento jav sa nazýva červený posun. Ak sa objekt k pozorovateľovi približuje, vlnová dĺžka sa bude naopak skracovať, jedná sa o modrý posun. Obidva tieto javy sú zapríčinené tzv. Dopplerovým javom.

V astronómii je tento jav pozorovateľný hlavne na galaxiách. Červený posun galaxií ako prvý popísal Edwin Hubble, kedy zároveň objavil fakt, že tento červený posun je tým väčší, čím je galaxia vzdialenejšia. Tento fakt viedol k teórii o rozpínaní vesmíru.

Červený posun galaxií má v astrofyzike veľký význam, keďže je často jediný indikátor, pomocou ktorého sa dá určiť relatívna vzdialenosť galaxie. Môže byť odmeraný buď pomocou spektroskopie, toto meranie je presné avšak časovo veľmi náročné. Druhý spôsob merania červeného posunu je pomocou fotometrie, tento spôsob je menej presný, je náchylný na systematické chyby ale je omnoho rýchlejší a je menej náročné aplikovať ho na veľké vzorky objektov.



Obr. 5 – Červený posun vybraných galaxií

Avšak dostupnosť veľkého množstva fotometrických dát spolu s ich spektroskopicky nameranými červenými posunmi vytvorila možnosť využiť neurónovú sieť s kontrolovaným

učením pre relatívne presné určenie červeného posunu galaxií na základe fotometrických údajov.

Metóda využíva kombináciu dvoch typov neurónových sietí. Prvá neurónová sieť, bez kontrolovaného učenia zhlukuje body v príznakovom priestore na základe vzťahu medzi fotometricky a spektroskopicky nameranými údajmi. Nad týmito zhlukmi je vytrénovaná druhá neurónová sieť s kontrolovaným učením, ktorá na základe fotometrických údajov je schopná zaradiť meranie do niektorého zo zhlukov. Pomocou toho je možné kompenzovať nepresnosti merania a systematické chyby merania, keďže tieto nedostatky sú v rámci jedného zhluku podobné. Tým je možné spresniť fotometricky nameraný červený posun galaxií.

#### E. Analýza premenných hviezd

Zmeny v jasnosti premenných hviezd môže spôsobiť viacero príčin. Pulzujúce premenné hviezdy menia svoju jasnosť z dôvodu periodického prevládania gravitačnej sily a sily vznikajúcej pri spaľovaní vodíka. Kataklizmatické premenné hviezdy sú supernovy, alebo novy, čiže zmenu ich jasností spôsobuje masívny výbuch takejto hviezdy. Keďže takýto výbuch danú hviezdu zničí, jedná sa o neperiodické premenné hviezdy. Ďalším typom sú geometrické premenné hviezdy, tie sa delia na zákrytové dvojhviezdy a planetárne zákrytové hviezdy. Zákrytové dvojhviezdy menia svoju jasnosť vzájomnou pozíciou, napríklad keď sa jedna hviezda dostane za druhú, jasnosť dvojhviezdy poklesne. Planetárne zákrytové hviezdam jasnosť poklesne keď sa planéta dostane pred hviezdu a tým zakryje časť hviezdneho kotúča.

Pri určovaní typu premenných hviezd sa využíva frekvenčný rozklad signálu danej hviezdy, t.j. časovej závislosti zdanlivej svietivosti hviezdy. Najčastejšou metódou pre frekvenčnú analýzu signálu je Fourierova analýza, avšak tá si vyžaduje párne vzorkovaný signál, čo nie je stále možné dosiahnuť. Jedna možnosť je prevzorkovať celé meranie na párne pomocou interpolácie, čo ale spôsobuje veľké zosilnenie nežiaduceho šumu. Inou možnosťou je použiť frekvenčný estimátor a nelineárnu neurónovú sieť na extrakciu hlavných častí autokorelačnej matice.

#### IV. ZÁVER

Neurónové siete majú široké uplatnenie vo vedách skúmajúcich vesmír, kde postupne nahrádzajú monotónnu činnosť človeka, hlavne v prípade klasifikácii veľkého množstva objektov. S rýchlym nárastom výkonu a klesajúcou cenou výpočtovej techniky sa stáva neurónová sieť ideálnym prostriedkom pre spracovanie získaných dát. Dokonca v prípade použitia grafických jadier pre paralelné výpočty neurónovej siete, je možné celé spracovanie rádovo urýchliť.

## V. REFERENCIE

- [1] R. Tagliaferri, G. Longo, L. Milano, F. Acernese, F. Barone, A. Ciaramella, "Neural networks in astronomy", 2003.
- [2] M. C. Storrie-Lombardi, O. Lahav, L. Sodre, J. L. Storrie-Lombardi, "Morphological classification of galaxies by Artificial Neural Networks", 1992
- [3] S. C. Odewahn and M. L. Nielsen, "Star-galaxy separation using neural networks", 1994
- [4] H. P. Singh, R. K. Gulati and R. Gupta, "Stellar spectral classification using principal component analysis and artificial neural networks", 1998