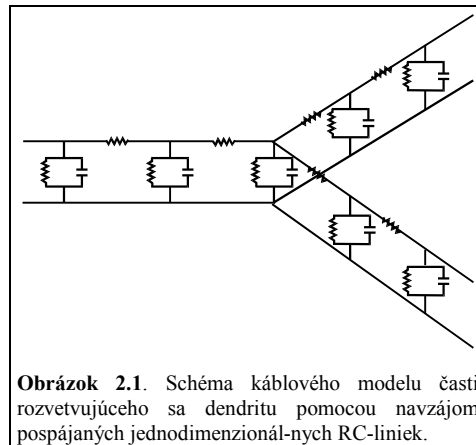


## 2. História neurónových sietí

### 2.1 Modelovanie nervovej bunky

Jedna z tém v histórii neurónových sietí súvisí s modelovaním samotnej nervovej bunky. V roku 1952 Hodgkin a Huxley na základe meraní generovania a šírenia sa akčného potenciálu v axóne sépie navrhli sústavu diferenciálnych rovníc, ktoré popisujú dynamiku iónových prúdov na aktívnej excitabilnej membráne [23]. Základom týchto rovníc je popis kinetiky membránových iónových kanálov riadených membránovým napätím a výsledkom je veľmi presná výpočtová reprodukcia generovania a šírenia sa akčných potenciálov. Významnou postavou v teoretickom a experimentálnom skúmaní nervového systému je Sir John Eccles [10]. Venoval sa hlavne synaptickému prenosu a popisu iónových prúdov vyvolaných na postsynaptickej membráne pôsobením neuromediátorov. Na popis použil terminológiu elektrických obvodov zložených z rezistorov a kondenzátorov. Matematické štúdie šírenia sa elektrických impulzov v nervových bunkách a ich porovnávanie s elektrickými meraniami na skutočných neurónoch pokračovali v prácach Wilfrida Ralla [47, 48]. Rall aplikoval káblOVú teóriu lorda Kelvina na neurón veľmi úspešne, t.j. riešenia rovníc sa zhodovali s meraniami na skutočných neurónoch. V jeho lineárnej káblovej teórii neurónu je soma a každý segment výbežkov bunky (t.j. axónov alebo dendritov) reprezentovaný jednodimenzionálnou RC-linkou s distribuovanými parametrami (obr. 2.1). Analytické riešenie takéhoto systému reprezentujúceho reálny neurón s tisíckami dendritov v dendritickom strome nie je možné a numerické riešenie je veľmi náročné. Pre isté geometrie dendritických stromov navrhol Rall výpočtovo ekvivalentnú reprezentáciu pomocou jedného zužujúceho sa kábla. Butz a Cowan [5] vyvinuli prístup k integrovaniu takéhoto veľkého systému diferenciálnych rovníc s komplikovanými okrajovými podmienkami pre dendritický strom ľubovoľnej geometrie. Využitie tohto prístupu v praxi je vlastne obmedzené len neschopnosťou experimentálne presne zistiť hodnoty odporov a kapacít na všetkých miestach dendritického stromu. Preto sa v praktickom použití káblovej teórie na modelovanie neurónu používajú rozličné aproximácie, v ktorých vystupujú merateľné alebo odvoditeľné parametre. De Schutter [9] podáva prehľad dostupného softwaru na modelovanie jednej nervovej bunky, ako aj malých sietí z nich zložených, na základe káblovej teórie. Okrem iného, práce Ralla a jeho kolegov sú významné v tom, že ukázali, že geometria dendritického stromu determinuje odpoveď neurónu na signály, ktoré prichádzajú od ostatných neurónov. Ukázali, že odpoveď neurónu je vždy iná pre iný priestorovo-časový vzorec aktivácie jeho synáps. Koch a Poggio študovali pomocou káblovej teórie interakcie medzi excitačnými synapsami umiestnenými na dendritických trňoch a vypočítali, že účinnosť synapsy je veľmi citlivá na zmenu rozmerov trňov [28, 29]. K takýmto zmenám môže dochádzať ako pri indukcii dlhodobej potenciácie synaptickej účinnosti (LTP), tak aj pri prirodzenej stimulácii neurónov [11]. U nás sa káblovej teórii neurónu venovali Dr. Peter Fedor so spolupracovníkmi [14], ktorí navrhli hypotézu



vysvetľujúcu mechanizmus vedúci od stimulácie excitačnej synapsy umiestnenej na dendritickom tŕni ku zmene rozmerov tŕňa.

## 2.2 Hebbovo pravidlo


V r. 1949 vyšla kniha kanadského psychológa Donalda Hebba "The Organization of Behavior", jedna z najcitovanejších prác v obore [19]. Hebb v nej navrhol, že účinnosti spojení medzi neurónmi v mozgu sa permanentne menia ako sa jedinec adaptuje a učí nové veci, a to podľa nasledovného pravidla: *"When an axon of cell A ... excite(s) cell B and repeatedly or persistently takes part in firing it, some growth process or metabolic change takes place in one or both cells so that A's efficiency as one of the cells firing B is increased"* (Keď má axón bunky A excitačný účinok na bunku B, a opakovane alebo stále sa zúčastňuje na jej aktivácii, v jednej alebo v oboch bunkách prebehne nejaký rastový proces alebo metabolická zmena, takže účinnosť bunky A ako jednej z buniek, ktoré aktivujú B, vzrastie). To má za následok, že skupina neurónov, ktoré sú navzájom pospájané, a ktoré sú synchronne aktivované, bude mať tendenciu vytvárať tzv. bunečné zoskupenie (angl. *cell assembly*), v ktorom sú neuróny pospájané silnejšie. Podstatná invencia Hebbovej predpovede, odvtedy experimentálne nespočetne veľakrát potvrdená je, že nová informácia je reprezentovaná distribuovane prostredníctvom zmeny účinností mnohých synaptických spojení.

## 2.3 McCullochov-Pittsov model

V r. 1943 McCulloch a Pitts predstavili prvý model neuronovej siete [41]. Aplikovali sieť zloženú z tzv. formálnych neurónov na symbolickú logiku, na výroky zložené z elementárnych logických operácií ( $x$  AND  $y$ ,  $x$  OR  $y$ , NOT  $x$ ). Obr. 2.2 ilustruje niekoľko príkladov McCullochových-Pittsových formálnych neurónov. Tieto formálne neuróny sú vlastne jednoduché logické prepínače, a ich prepínanie prebieha synchronne a v diskretných

časových intervaloch. Hodnoty synaptických váh a prahov sú fixné. McCulloch a Pitts ukázali, že všetky procesy, ktoré sa dajú popísať konečným počtom symbolických výrazov, teda jednoduchá aritmetika, klasifikácia, záznam konečnej množiny dát, rekurzívna aplikácia logických pravidiel a pod., sa dajú realizovať sieťou zloženou z takýchto elementov. Ak je táto sieť nekonečne veľká, tak je výpočtovo ekvivalentná univerzálnemu Turingovmu stroju [41, 52].

V r. 1956 John von Neumann, matematik a významná postava vo vývoji digitálnych počítačov, vyriešil problém spoľahlivosti McCullochových-Pittsových sietí v prípade hardwarového poškodenia [44]. Zaviedol redundanciu – viacero formálnych neurónov vykonáva tú istú prácu. Tak napr. jeden bit informácie (výber medzi "1" a "0") nie je signalizovaný výstupom jedného logického prepínača, ale synchronnou aktiváciou mnohých neurónov: "1" dostávame, keď viac ako polovica neurónov je aktívnych a "0", keď je aktívnych menej ako polovica neurónov. Winograd a Cowan [55] zaviedli navyše do neurónovej siete aj distribuovanú reprezentáciu informácie. To znamená, že 1 bit informácie je reprezentovaný redundantne (ako u von Neumanna) a navyše, každý formálny neurón čiastočne reprezentuje mnoho bitov.



## 2.4 Inšpirácia z teórie spinových skiel

V r. 1954 neuroanatóm Cragg a fyzik Temperley navrhli, že pamäťové stavy v mozgu sú reprezentované oblasťami aktívnych a neaktívnych neurónov [8]. Viedla ich k tomu analógia s tuhými látkami, kde sa môžu striedať domény "dolu" alebo "hore" orientovaných spinov a kde sa vďaka vzájomným interakciám medzi prvkami takéto domény vytvoria a udržia. O 20 rokov neskôr, v r. 1974, prišiel k tejto myšlienkovj konštrukcii aj Little, a to

na základe matematickej analýzy mriežkového spinového systému [34]. Táto línia myslenia bola zavŕšená článkom Johna Hopfielda "Neurónové siete a fyzikálne systémy s emergentnými kolektívnymi výpočtovými schopnosťami", v ktorom reinterpretoval Kirkpatrickovu, Sherringtonovu a Isingovu teóriu spinových skiel do jazyka neurónových sietí a vytvoril tak model robustnej autoasociatívnej pamäti, ktorá spoľahlivo rozpoznáva zašumené vzory aj keď je 80% spojení medzi neurónmi zničených [24, 26, 27]. Tým sa inicioval mohutný prúd prác skúmajúcich neurónové siete pomocou exaktného fyzikálneho aparátu, hlavne z oblasti magnetických systémov [2]. V Hopfieldových neurónových sieťach je každý neurón spojený s každým symetrickou väzbou. Všetky neuróny sú zároveň vstupom a výstupom siete (viď obr. 8.1). Tieto siete sa neučia, ale ich pamäťové stavy sú predprogramované v matici synaptických spojení, ktorá je skonštruovaná tak, aby pamäťové stavy tvorili atraktory v stavovom priestore. V týchto neurónových sieťach je informácia reprezentovaná distribuovane a redundantne. Neaktívne neuróny sú rovnako dôležité ako aktívne, lebo vlastne konkrétna distribúcia aktivity a "neaktivity" v celej sieti je kódom informácie reprezentovanej v danom okamihu (angl. *coarse coding*). Hopfieldova neurónová sieť funguje ako obsahom adresovaná pamäť (angl. *content addressable memory*), t.j. na základe prítomnosti časti informácie na vstupe dokáže obnoviť celú informáciu.

## 2.5 Perceptróny

V r. 1958 Frank Rosenblatt ukázal, že McCullochove-Pittsove siete s modifikovateľnými synaptickými váhami sa dajú natréňovať tak, aby vedeli rozpoznávať a klasifikovať objekty [49]. Vymyslel pre ne názov "perceptróny" (viď obr. 5.8). Hlavná myšlienka jeho tréningovej procedúry je takáto: najskôr zaznamenajme odpoveď každého formálneho neurónu na daný podnet. Ak je odpoveď správna, nemodifikujeme váhy. Ak je odpoveď daného neurónu nesprávna, potom modifikujeme váhy všetkých aktivovaných vstupných synáps, a to nasledovným spôsobom: ak má byť neurón aktívny a nie je, zväčšime ich, a naopak, ak má byť na výstupe neurónu 0 a nie je, zmenšime ich. Rosenblattova tréningová procedúra je založená na znalosti toho, ktoré vzory (reprezentujúce objekty) patria do ktorej triedy. Jeho idea modifikácie váh spojení na základe korekcie chýb tvorí základ mnohých algoritmov učenia s pomocou učiteľa, ktoré sa používajú dodnes. V r. 1960 Widrow a Hoff použili podobné pravidlo na učenie pre ich model neurónového klasifikátora nazvaného ADALINE (ADaptive LInear NEuron) [54]. Prvýkrát ukázali, že počas učenia sa minimalizuje suma štvorcov chýb, čiže počas učenia sa minimalizuje nejaká globálna funkcia systému.

V r. 1969 Minsky a Papert vo svojej knihe "Perceptróny: úvod do výpočtovej geometrie" poukázali na obmedzenia perceptrónov [42]. Ukázali, že tieto siete vôbec nie sú výpočtovo univerzálne a nedokážu riešiť všetky triedy problémov. Hlavne však išlo o to, že perceptróny nedokážu riešiť tzv. lineárne neseparovateľné problémy. Klasickým najjednoduchším príkladom zlyhania je logická funkcia XOR (vylučujúce alebo). V tom čase nebolo známe žiadne pravidlo učenia (t.j. modifikácie synaptických váh) v umelých neurónových sieťach, nevyhnutné na implementáciu výpočtov tohoto typu. Minsky a Papert usúdili, že bude užitočnejšie, keď sa výskum zameria iným smerom.

Tento problém bol vyriešený až skoro o 20 rokov neskôr, v r. 1986, keď autori Rumelhart, Hinton a Williams zaviedli pravidlo učenia metódou spätného šírenia sa chýb pre viacvrstvové perceptróny (angl. *error back-propagation learning*) [50]. Formálne neuróny v ich perceptrónoch však už nie sú jednoduché logické prepínače McCullochovho-Pittsovho typu, ale analógové elementy so spojitou vstupno-výstupnou funkciou (najčastejšie sigmoidálneho tvaru, pozri napr. obr. 8.6). Hoci to nie je absolútne univerzálny algoritmus schopný naučiť sieť riešiť ľubovoľnú výpočtovú úlohu, predsa len dokáže vyriešiť mnoho lineárne neseparovateľných problémov (vrátane XOR). Veľa úsilia v súčasnej výskumnej a aplikačnej aktivite sa sústreďuje práve na “backprop” a jeho modifikácie. Metóda učenia pomocou spätného šírenia sa chýb je aplikovateľná len na dopredné troj- a viacvrstvové perceptróny, v ktorých neuróny nie sú spojené každý s každým, ale vzájomne nespojené neuróny v rámci jednej vrstvy posielajú spojenia dopredným spôsobom (jednosmerne) ku všetkým neurómom v ďalšej vrstve (pozri obr. 5.3 a obr. 5.17). Stav neurónov v prvej vrstve predstavujú vstup do siete a stavy neurónov v poslednej vrstve predstavujú výstup siete. Jedno- a viacvrstvové perceptróny tiež reprezentujú informáciu redundantne a distribuovane, a fungujú ako obsahom adresovaná pamäť. Sú schopné učiť sa na príkladoch, a samy nájst príznaky spoločné prvkom (vzorom) patriacim do tej istej triedy. Extrakcia príznakov prebieha vo vnútornej, tzv. skrytej vrstve neurónov (skrytých vrstiev môže byť aj viac ako jedna). Avšak pri učení je potrebná znalosť toho, ktoré prvky (vzory) patria do ktorej triedy. Až po natrénovaní sú tieto siete schopné zovšeobecňovať, t.j. správne klasifikovať nové vzory. Viacvrstvové siete sú veľmi dobré aj na aproximáciu spojitých funkcií.

Teoretické odvodenie učenia pomocou algoritmu spätného šírenia sa chýb je založené na minimalizácii objektívnej funkcie, ktorá vyjadruje celkovú chybu, t.j. rozdiel medzi želaným a skutočným výstupom siete. Ronald Williams a David Zipser použili metódu gradientovej minimalizácie chybovej funkcie na odvodenie algoritmu spätného šírenia sa chýb v čase na tréningovanie rekurentných sietí [53]. V rekurentnej sieti posielajú neuróny v každej vrstve spojenia nielen k nasledujúcim vrstvám, ale aj k predchádzajúcim, a môžu byť pospájané aj medzi sebou (pozri obr. 6.6). Rekurentné spojenia umožňujú uchovať a vyvolať informáciu, ktorá sa vyskytla v minulosti a použiť ju pre súčasný výpočet. To znamená, že rekurentné siete sú dobré na zapamätávanie a predikciu časových postupností vzorov.

Hinton a Sejnowski [22] vymysleli algoritmus učenia pre ľubovoľné, úplne alebo čiastočne rekurentné stochastické siete, ktoré majú symetrické synaptické spojenia. Takéto siete sa dajú považovať za zovšeobecnenie Hopfieldovej neurónovej siete, tak aby táto sieť obsahovala aj skryté neuróny na extrakciu príznakov. Takisto ako v dopredných sieťach, aj tu sa adaptujú hodnoty váh synaptických spojení v dôsledku pôsobenia vstupov a znalosti o tom, ktoré vstupné vzory sú asociované s ktorými výstupnými konfiguráciami aktivity. Keďže takáto sieť má tú vlastnosť, že pravdepodobnostná distribúcia jej možných stavov (konfigurácií aktivity) je totožná s Boltzmannovým rozdelením, nazvali ju jej autori Boltzmannov stroj (angl. *Boltzmann machine*).

V súčasnosti sa skúmajú dopredné a rekurentné siete, ktorých prvky nemajú sigmoidálnu vstupno-výstupnú prechodovú funkciu, ale tzv. radiálnu bázovú funkciu (angl. *radial basis function*, RBF). Najčastejšie je to aktivačná funkcia v tvare gausiánu [43]. Takáto prechodová funkcia sa veľmi podobá na tvar recepčných polí v reálnom neurónovom

systeme a v mnohých prípadoch RBF siete dosahujú lepšie výsledky ako siete s prvkami, ktoré majú sigmoidálnu prechodovú funkciu.

## 2.6 Samoorganizácia

Článok Minského a Paperta znamenal veľkú ranu teoretickému výskumu perceptrónov ako univerzálnych výpočtových systémov. Pred objavením algoritmu učenia metódou spätného šírenia sa chýb sa preto výskum v neurónových sieťach začal zameriavať hlavne na učenie bez učiteľa a na systémy, ktoré sú schopné samoorganizácie, t.j. ktoré sú schopné naučiť sa klasifikovať vzory aj bez explicitnej informácie o tom, ktoré vzory do ktorej triedy patria. Neurónová sieť musí objaviť sama prototypy, príznaky, korelácie, kategórie alebo "štatistické pravidelnosti a nepravidelnosti" vo vstupných dátach a zakódovať ich na svojom výstupe. Je zaujímavé, že učenie v týchto typoch neurónových sietí prebieha podľa Hebbovho pravidla a jeho rôznych modifikácií, ktoré však nemenia jeho princíp. Tu spomeňme najmä mená ako von der Malsburg [35], Grossberg [17, 18], Bienenstock so spolupracovníkmi [3], Oja [45, 46], Sanger [51], Linsker [33].

Ojove a Sangerove neurónové siete sú schopné nájsť vo vstupných dátach hlavné komponenty, t.j. smery, v ktorých majú dáta najväčšiu varianciu, a redukovať tak dimenzionalitu mnohorozmerných dát. Sú efektívnymi nástrojmi na štatistickú analýzu hlavných komponent (angl. *principal component analysis*). Grossberg je okrem iného známy aj svojou teóriou adaptívnej rezonancie (angl. *adaptive resonance theory*) a jej implementáciou pomocou neurónovej siete ART1 a ART2 [6, 7]. Von der Malsburg [35], Bienenstock, Cooper a Munro (BCM) [3] a Linsker [33] sa venovali modelovaniu samoorganizácie v skutočných neurónových sieťach zrakovej dráhy v mozgu. Na základe jednoduchých princípov ukázali, ako sa môžu vytvárať recepcné polia neurónov v zrakovej kôre. BCM neuróny a siete z nich zložené sú schopné vyhľadávať projekcie (angl. *projection pursuit*). V tomto procese sa synaptické váhy adjustujú na také hodnoty, ktoré určujú smery (projekcie), v ktorých majú vstupné dáta viacmodálne rozdelenie [25].

Významným príspevkom k teórii samoorganizujúcich sa neurónových sietí sú práce Teuvo Kohonena [30, 31, 32]. Jeho samoorganizujúce sa neurónové siete sa učia bez učiteľa a súťažia medzi sebou o vstupy. Algoritmus učenia je navrhnutý tak, že zobrazenie vstupného priestoru na diskretnú geometricky usporiadanú množinu umelých neurónov zachováva topológiu (pozri obr.7.8 a obr. 7.26). To znamená, že susedné neuróny odpovedajú najlepšie na susedné vstupy, t.j. vytvorí sa topografická mapa vstupného priestoru. Topografický princíp je jedným z hlavných princípov organizácie spojení v každom sensorickom systéme v skutočnom mozgu.

Zlúčenie dvoch princípov učenia, bez učiteľa a s učiteľom, viedlo k návrhu neurónových sietí s hybridným učením, kde sa prvé vrstvy učia bez učiteľa a vyššie vrstvy sa učia s učiteľom [20, 21]. Takéto siete využívajú prednosti oboch typov učenia a predstavujú systémy vykonávajúce klasifikáciu na základe hierarchických máp príznakov vstupných dát.

U nás sa samoorganizácii a učeniu neurónových sietí bez učiteľa venoval Dr. Peter Fedor [12, 13]. Navrhol vlastný originálny algoritmus na učenie formálnych neurónov založený na Hebbovom pravidle. Svoj model nazval diskriminačný neurón, tzv. D-neurón, pretože v priebehu pôsobenia vstupných vzorov sa jednotlivé D-neuróny "naladila" na diskrimináciu

(rozlíšenie) jednotlivých vzorov, vstupných vektorov. Siete zložené z týchto formálnych neurónov sú schopné rozpoznávať a generovať časové postupnosti vzorov, a to invariantne vzhľadom k trvaniu jednotlivých vzorov a dĺžke prestávok medzi nimi. Okrem toho, dynamicky menia svoju architektúru. Neskôr tieto siete aplikoval na komponovanie jednoduchých melódií [15, 16].

## 2.7 Spät' k mozgu

Modelovanie činnosti nervového systému sa neskončilo pri modelovaní spracovania signálov v jednej nervovej bunke. Z prác, ktoré sa pokúsili biologicky realisticky modelovať a vysvetľovať činnosť mozgu a jeho jednotlivých častí sú najznámejšie a stále rešpektované práce Davida Marra. V roku 1969 publikoval teóriu mozočka (lat., *cerebellum*), v ktorej na základe výpočtovej analýzy neurónových obvodov mozočka vysvetlil, že mozoček funguje ako asociatívna obsahom adresovaná pamäť, ktorú mozog "trénuje" na riadenie a vykonávanie sekvencií zložitých vôľou riadených (voluntárnych) pohybov, takých ako napr. plávanie, hranie na klavír, šoférovanie, a pod. [36, 4]. V Marrovej teórii je každému z piatich hlavných typov neurónov, ktoré sa nachádzajú v mozočku, priradená špecifická funkcia v učení a vyvolávaní vzorcov aktivity. Jeho hypotéza asociatívneho učenia sa výstupných cerebellárnych buniek definovala presne, kedy a ako sa tieto bunky učia, teda kedy a ako sa menia účinnosti synaptických spojení na týchto bunkách. Zatiaľ jeho teória nebola experimentálne ani potvrdená ani vyvrátená, hoci sa zdá, že v skutočnosti pravdepodobne bude správna jej malá modifikácia, ktorú navrhol Albus [1]. Marr aplikoval podobnú analýzu aj na neokortex [37] a na hipokampus (evolučne staršia časť hlavného mozgu, o ktorej sa vie, že hrá veľmi dôležitú úlohu v mechanizmoch pamäti) [38]. O týchto teóriách sa ešte nedá rozhodnúť, či sú správne alebo nie, ale experimenty ich zatiaľ skôr potvrdzujú ako vyvracajú. Týmto sa však Marrov príspevok k modelovaniu činnosti mozgu nekončí. Neskôr sa sústredil na videnie, ako napr. na detekciu hrán objektov a na stereo-videnie (schopnosť vnímať hĺbku, t.j. tretí rozmer, na základe binokulárnej disparity, tak ako to robíme stále a tiež keď sa bavíme pri prezeraní 3D obrázkov, ktoré sa vynárajú z farebných škvŕn) [39, 40]. Marr definoval tri úrovne popisu činnosti centrálného nervového systému: výpočtovú, algoritmickú a implementačnú. Napríklad vypracovanie výpočtovej úrovne popisu videnia znamená nájdenie optimálnych reprezentácií popisu obrazu v jednotlivých štádiách jeho spracovania, a nájdenie operátorov, pomocou ktorých možno takéto spracovávanie obrazu uskutočniť. Algoritmická úroveň popisu zahŕňa špecifikáciu konkrétnych algoritmov, ktoré by tieto výpočty realizovali. Implementačná úroveň zase špecifikuje "hardware" (biologický alebo iný), ktorý by tieto algoritmy realizoval. Marrov prístup predstavoval, a s malými modifikáciami dodnes predstavuje, akúsi metodickú paradigmu modelovania mozgovej činnosti.

## Literatúra

- [1] J.S. Albus. A theory of cerebellar function. *Mathematical Biosciences*, 10: 25-61, 1971.
- [2] D.J. Amit. *Modeling Brain Function. The World of Attractor Neural Networks*. Cambridge University Press, Cambridge, 1989.
- [3] E.L. Bienenstock, L.N. Cooper and P.W. Munro. Theory for the development of neuron selectivity: orientation specificity and binocular interaction in visual cortex. *Journal of Neuroscience*, 2: 32-48, 1982.
- [4] S. Blomfield and D. Marr. How the cerebellum may be used. *Nature*, 227: 1224-1228, 1970.
- [5] E. Butz and J.D. Cowan. Transient potentials in systems of arbitrary dendritic geometry. *Biophysical Journal*, 14: 661-689, 1974.
- [6] G.A. Carpenter and S. Grossberg. A massively parallel architecture for a self-organizing neural pattern recognition machine. *Computer Vision, Graphics, and Image Processing*, 37: 54-115, 1987a.
- [7] G.A. Carpenter and S. Grossberg. ART2: self-organization of stable category recognition codes for analog input patterns. *Applied Optics*, 26: 4919-4930, 1987b.
- [8] B.G. Cragg and H.N.V. Temperley. The organization of neurons: A cooperative analogy. *EEG Clinical Neurophysiology*, 6: 85-92, 1954.
- [9] E. De Schutter. A consumer guide to neuronal modeling software. *Trends in Neurosciences*, 15: 462-464, 1992.
- [10] J.C. Eccles. *The Physiology of Synapses*. Springer-Verlag, Berlin, 1964.
- [11] J.C. Eccles. Synaptic plasticity. *Naturwissenschaften*, 66: 147-153, 1979.
- [12] P. Fedor and V. Majerník. A neuron model as an universal element of self-learning networks for pattern recognition. *Biological Cybernetics*, 26: 25-34, 1977.
- [13] P. Fedor. Principles of the design of D-neuronal networks. I. A neural model for pragmatic analysis of simple melodies. *Biological Cybernetics*, 27: 129-146, 1977.
- [14] P. Fedor, L. Beňušková, H. Jakeš and V. Majerník. An electrophoretic coupling mechanism between efficiency modification of spine synapses and their stimulation. *Studia Biophysica*, 92: 141-146, 1982.
- [15] P. Fedor. Principles of the design of D-neuronal networks. I. Net representation for computer simulation of a melody compositional process. *International Journal of Neural Systems*, 3: 65-73, 1992a.
- [16] P. Fedor. Principles of the design of D-neuronal networks. II. Composing simple melodies. *International Journal of Neural Systems*, 3: 75-82, 1992b.
- [17] S. Grossberg. Adaptive pattern classification and universal recoding: I. Parallel development and coding of neural feature detectors. *Biological Cybernetics*, 23: 121-134, 1976a.
- [18] S. Grossberg. Adaptive pattern classification and universal recoding: II. Feedback, Expectation, Olfaction, Illusions. *Biological Cybernetics*, 23: 187-202, 1976b.
- [19] D. Hebb. *The Organization of Behavior*. J. Wiley and Sons, New York, 1949.
- [20] R. Hecht-Nielsen. Counterpropagation networks, *Applied Optics*, 26: 4979-4984, 1987.
- [21] R. Hecht-Nielsen. Applications of counterpropagation networks. *Neural Networks*, 1: 131-139, 1988.



- [22] G.E. Hinton and T.J. Sejnowski. Learning and relearning in Boltzmann machines. In: D.E. Rumelhart and J.L. McClelland, editors, *Parallel Distributed Processing: Explorations in the Microstructure of Cognition. Vol. 1. Foundations*, chapter 7, MIT Press/Bradford Books, Cambridge, MA, 1986.
- [23] A.L. Hodgkin and A.F. Huxley. A quantitative description of membrane current and its application to conduction and excitation in nerve. *Journal of Physiology*, 117: 500-544, 1952.
- [24] J.J. Hopfield. Neural systems and physical systems with emergent collective computational abilities. *Proceedings of the National Academy of Sciences of the USA*, 79: 2554-2558, 1982.
- [25] N. Intrator and L.N Cooper. Objective function formulation of the BCM theory of visual cortical plasticity: statistical connections, stability conditions. *Neural Networks*, 5: 3-17, 1992.
- [26] E. Ising. Beitrag zur Theory des Ferromagnetism. *Zeitschrift fur Physik*, 31:253-287, 1925.
- [27] S. Kirkpatrick and D. Sherrington. Infinite-ranged models of spin glasses. *Physical Review B*, 17: 4384-4403, 1978.
- [28] C. Koch and T. Poggio. A theoretical analysis of electrical properties of spines. *Proceedings of the Royal Society of London B*, 218: 455-477, 1983.
- [29] C. Koch, T. Poggio and V. Torre. Nonlinear interactions in a dendritic tree: Localization, timing, and role in information processing. *Proceedings of the National Academy of Sciences of the USA*, 80: 2799-2802, 1983.
- [30] T. Kohonen. An adaptive associative memory principle. *IEEE Transactions on Computers*, C-23: 444-445, 1974.
- [31] T. Kohonen. Self-organized formation of topologically correct feature maps. *Biological Cybernetics*, 43: 59-69, 1982.
- [32] T. Kohonen. *Self-Organization and Associative Memory (3rd ed.)*, Springer-Verlag, Berlin, 1989.
- [33] R. Linsker. From basic network principles to neural architecture. *Proceedings of the National Academy of Sciences of the USA*, 83: 7508-7512, 1986.
- [34] W.A. Little. The existence of persistent states in the brain. *Mathematical Biosciences*, 19: 101-120, 1974.
- [35] C. von der Malsburg. Self-organization of orientation sensitive cells in the striate cortex. *Kybernetik*, 14: 85-100, 1973.
- [36] D. Marr. A theory of cerebellar cortex. *Journal of Physiology*, London, 202: 437-470, 1969.
- [37] D. Marr. A theory for cerebral neocortex. *Proceedings of the Royal Society of London B*, 176: 161-234, 1970.
- [38] D. Marr Simple memory: a theory for archicortex. *Philosophical Transactions of the Royal Society of London B*, 262: 23-81, 1971.
- [39] D. Marr and T. Poggio. Cooperative computation of stereo disparity. *Science*, 194: 283-287, 1976.
- [40] D. Marr and E. Hildreth. Theory of edge detection. *Proceedings of the Royal Society of London B*, 207: 187-217, 1980.
- [41] W.S. McCulloch and W. Pitts. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5: 115-133, 1943.

- [42] M. Minsky and S. Papert. *Perceptrons: an introduction to computational geometry*. MIT Press, Cambridge, MA, 1969.
- [43] J. Moody and C. Darken. Fast learning in networks of locally-tuned processing units. *Neural Computation*, 1: 281-294, 1989.
- [44] J. von Neumann. Probabilistic logics and the synthesis of reliable organisms from unreliable components. In: C.E. Shannon and J. McCarthy, editors, *Automata Studies*, pages 43-98, Princeton University Press, Princeton, NJ, 1956.
- [45] E. Oja. A simplified neuron model as a principal component analyzer. *Journal of Mathematical Biology*, 15: 267-273, 1982.
- [46] E. Oja. Neural networks, principal components, and subspaces. *International Journal of Neural Systems*, 1: 61-68, 1989.
- [47] J. Rinzel and W. Rall. Transient response in a dendritic neuron model for current injected at one branch. *Biophysical Journal*, 14: 759-790, 1974.
- [48] W. Rall. Core conductor theory and cable properties of neurons. In: E.R. Kandel and Geiger S., editors, *Handbook of Physiology - The Nervous System I: Cellular Biology of Neurons*, volume 3, pages 39-97, American Physiological Society, Bethesda, MA, 1977.
- [49] F. Rosenblatt. The Perceptron, a probabilistic model for information storage and organization in the brain. *Psychological Review*, 62: 386-408.
- [50] D.E. Rumelhart, G.E. Hinton and R.J. Williams. Learning internal representations by error propagation. In: D.E. Rumelhart and J.L. McClelland, editors, *Parallel Distributed Processing: Explorations in the Microstructure of Cognition. Vol. 1. Foundations*, pages 318-363, MIT Press/Bradford Books, Cambridge, MA, 1986.
- [51] T.D. Sanger. Optimal unsupervised learning in a single-layer linear feedforward neural network. *Neural Networks*, 2: 459-473, 1989.
- [52] A.M. Turing. On computable numbers with an application to the Entscheidungsproblem. *Proceedings of London Mathematical Society*, XLII: 230-265, 1937.
- [53] R.J. Williams and D. Zipser. A learning algorithm for continually running fully recurrent neural networks. *Neural Computation*, 1: 268-278, 1989.
- [54] B. Widrow and M.E. Hoff. Adaptive switching circuits. *WESCON convention record*, IV: 96-104, 1960.
- [55] S. Winograd and J.D. Cowan. *Reliable Computation in the Presence of Noise*. MIT Press, Cambridge, MA, 1963.