

Reti neurali: ipotetiche forme di vita artificiale o realistici calcolatori alternativi?

Giorgio Meini

Che cosa sono le reti neurali?

Sono alcuni anni ormai che si parla molto - non solo tra informatici - di reti neurali o, in breve, di RN (in inglese: *Neural Networks* o *NN*). Ma che cosa sono le reti neurali? Da una prima analisi della sterminata letteratura prodotta in questo ultimo decennio sull'argomento si ricava una forte impressione di eterogeneità; le diverse risposte, infatti, spaziano su un campo di discipline piuttosto vasto:

- modelli di neurobiologia (neuroanatomia e neurofisiologia);
- modelli di psicologia cognitiva e percettiva;
- un nuovo paradigma per l'intelligenza artificiale (IA o, in inglese, *AI* da *Artificial Intelligence*);
- sistemi sensoriali artificiali e di controllo motorio per applicazioni di robotica avanzata;
- sistemi di computazione parallela e distribuita adatti, in particolare, a risolvere complessi problemi di ottimizzazione;
- tecnologie per memorie associative insensibili al rumore e capaci di riconoscere e di classificare *pattern*;
- generatori adattivi di regole per sistemi di conoscenza o di controllo *fuzzy*.

In questo scritto, prima di presentare come esempio un programma di simulazione di un importante modello di rete neurale, cercherò di svolgere un'analisi comparativa di queste molteplici risposte avente per fine una visione sintetica dell'argomento. La prima parte dell'articolo è una riduzione adattata dell'introduzione alla mia dissertazione di laurea [1]; una "lezione" di carattere introduttivo avente per argomento le RN è stata pubblicata sul n. 42 (Dicembre 1995) di *Computer Programming* [2].

Neuroscienze, psicologia cognitiva, intelligenza artificiale e reti neurali

Una definizione di essere vivente - senza dubbio molto imperfetta, ma purtroppo molto diffusa nei testi di biologia dello scorso decennio (oggi è di moda una visione della vita biologica fondata sul concetto di "programma" genetico) - ne sottolinea le caratteristiche di autoconservazione (un organismo che svolge attività metabolica è descrivibile come un sistema termodinamico aperto con entropia locale negativa), autoriproduzione e autoregolazione (riducendo il comportamento all'interazione cibernetica, in particolare senso-motoria, con l'ambiente si può affermare che l'organismo "apprende" una rappresentazione interna del mondo esterno). Quando le discipline non biologiche, come la teoria dei sistemi, si sono ispirate a modelli degli esseri viventi hanno spesso rivolto la loro attenzione alle funzioni di autoregolazione e, in particolare, alla retroazione (*feedback*) finalizzata al controllo della relazione organismo-ambiente: acquisizione di informazione dall'ambiente (compito del sistema sensoriale) - "comparazione" dell'informazione acquisita con il modello interno (innato od appreso) del mondo esterno (svolta, in alcuni organismi viventi, dal sistema nervoso) - attuazione di un "comportamento" di modifica della relazione dell'organismo con l'ambiente. In questa ottica lo studio di tipo analitico di un essere vivente può essere finalizzato ad ottenere un modello descrittivo, sempre parziale rispetto alle complesse ed interagenti funzionalità dell'organismo; l'eventuale implementazione, o simulazione, del modello realizza (sintesi) un sistema artificiale di ispirazione biologica. Lo studio analitico del sistema

nervoso e del comportamento degli animali e dell'uomo è oggetto della neurobiologia (neuroanatomia e neurofisiologia) e della psicologia.

Le reti neurali sono realizzazioni sintetiche ispirate dai modelli della neurobiologia, mentre l'intelligenza artificiale è la scienza dell'implementazione dei modelli sviluppati dalla psicologia della percezione sensoriale e dei processi cognitivi. La classica suddivisione dell'IA in "tesi forte" (modelli esplicativi dei processi percettivi e cognitivi) e "tesi debole" (applicazioni ispirate da modelli delle scienze cognitive, come i sistemi esperti) ha il suo corrispettivo concettuale nel divario esistente tra le RN che sono modelli neurobiologici, eventualmente orientati a giustificare alcune osservazioni proprie delle neuroscienze e della psicologia, e le RN impiegate come tecnologia per risolvere problemi specifici che nascono in alcuni campi di applicazione. La distanza concettuale che ancora separa le neuroscienze dalle scienze cognitive si riflette nella distanza tra modelli di reti neurali e approcci dell'intelligenza artificiale: nonostante i tentativi di alcuni ricercatori che vedono nelle RN la "microstruttura" dei processi cognitivi, non esiste ancora un livello "intermedio" di comprensione o, nel campo applicativo, di implementazione.

Definizioni per le reti neurali

"Reti neurali artificiali sono reti interconnesse in via massivamente parallela di semplici elementi (solitamente adattivi), e delle loro organizzazioni gerarchiche, intese per interagire con gli oggetti del mondo reale in modo analogo ai sistemi nervosi biologici." [T. Kohonen (Helsinki University of Technology), *An Introduction to Neural Computing*, in "Neural Networks", Vol. 1, 1988]

A questa definizione sintetica è possibile contrapporre altre di tipo più analitico, come la seguente che è anche sufficientemente generale da comprendere, come casi particolari, molti dei più noti modelli di rete neurale. David Rumelhart, James McClelland e il gruppo di ricerca PDP (*Parallel Distributed Processing*) dell'Istituto di Scienze Cognitive dell'Università di San Diego in California definiscono una rete neurale per mezzo di 8 aspetti caratteristici (si veda la **figura 1** ripresa da **[3]**):

1. l'insieme delle unità elementari (neuroni artificiali) indicate con u_j ;
2. lo stato di attivazione delle singole unità avente valore $a_i(t)$ all'istante t ;
3. la loro funzione di uscita $f_i(a_i)$ (generalmente una funzione di *threshold* che non propaga all'esterno dell'unità valori di attivazione troppo bassi);
4. lo schema di interconnessione della rete neurale (topologia dei collegamenti unidirezionali da u_i a u_j ai quali sono associati i coefficienti "sinaptici" w_{ij} che agiscono sui segnali propagati);
5. la regola di propagazione dell'informazione nella rete (interpretazione, generalmente moltiplicativa, dei coefficienti trasmissivi w_{ij} relativi alle connessioni tra le singole unità);
6. la regola di attivazione delle unità elementari (calcolo del nuovo stato di attivazione in funzione dello stato e degli *inputs* attuali, secondo una legge che è generalmente di tipo additivo, eventualmente con limitazioni superiori ed inferiori per il valore di attivazione);
7. la regola di apprendimento della rete (modificazione, autonoma o controllata dall'esterno, dei coefficienti delle interconnessioni e dei valori di soglia delle funzioni di uscita delle unità);
8. l'ambiente esterno alla rete (una funzione stocastica del tempo definita sullo spazio dei *pattern* che rappresentano tutti i possibili *input* della rete).

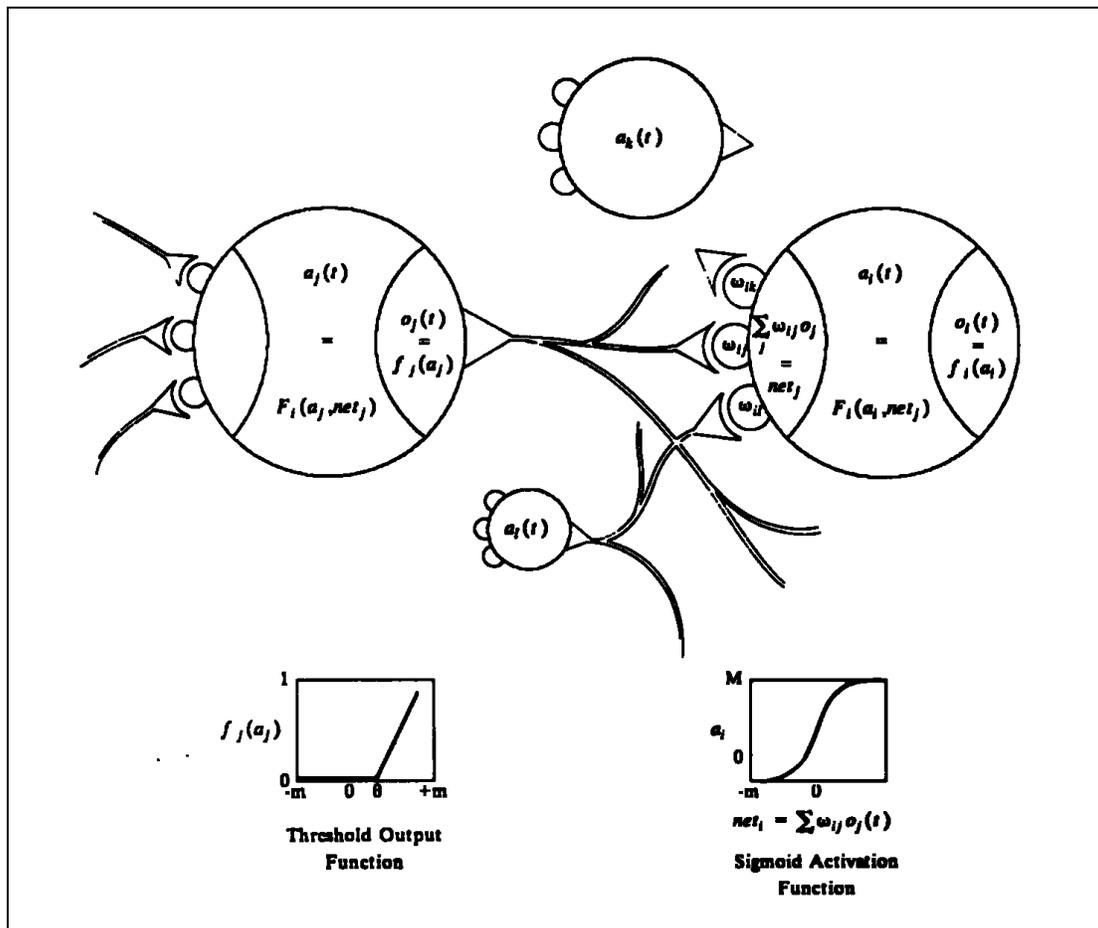


Figura 1 - una definizione di rete neurale (da: D. Rumelhart & J. McClelland, "Parallel Distributed Processing" Vol. 1, MIT Press, 1988)

Stephen Grossberg e Gail Carpenter del Centro per i Sistemi Adattivi dell'Università di Boston hanno unificato sotto l'aspetto matematico molte diverse definizioni di RN ricorrendo al concetto di filtro adattivo (**figura 2** ripresa da [4]) strutturato come segue:

- I. un primo livello F_1 le cui unità registrano il *pattern* fornito come ingresso alla rete;
- II. un insieme di segnali S_i che percorrono le connessioni caratterizzate dai coefficienti w_{ij} ;
- III. un secondo livello F_2 il cui *pattern* di attività è determinato da una funzione caratteristica del particolare tipo di RN e che può, nelle architetture più semplici, rappresentare il "risultato" fornito dalla rete come risposta alla stimolazione esterna.

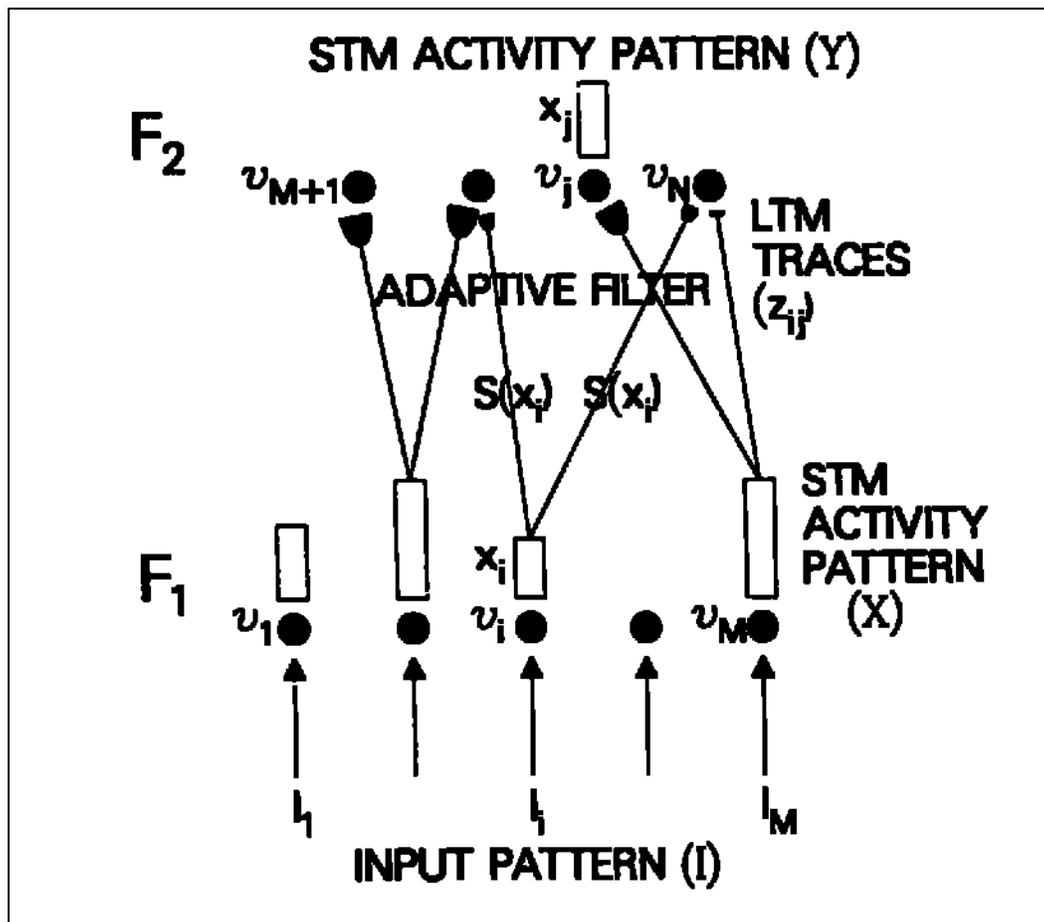


Figura 2 - il formalismo del filtro adattivo (da: G. Carpenter & S. Grossberg, "Self-Organizing Neural Networks Architectures for Real-Time Adaptive Pattern Recognition", in: H. Haken (ed.), "Neural and synergetic computers", Springer-Verlag)

Caratteristiche delle reti neurali

Tutti i modelli di RN (Perceptron, Adaline, Back-propagation, Kohonen, Hopfield, Boltzmann Machine, BAM, ART, ...) sono caratterizzati dai seguenti aspetti:

- complessità delle singole unità;
- architettura e topologia della rete;
- elaborazione parallela, distribuita e "analogica" - cioè non "simbolica" - dell'informazione;
- proprietà sinergiche emergenti dalla cooperazione tra unità;
- rappresentazione e memorizzazione delle informazioni;
- dinamica della rete e "rilassamento" in uno stato attrattore stabile;
- apprendimento ed auto-organizzazione come conseguenza della competizione tra unità.

NEURONI ARTIFICIALI

Le unità che interconnesse formano una rete neurale artificiale sono sempre, soprattutto se confrontate con la complessità dei reali neuroni biologici, elementi la cui attività è regolata da leggi relativamente semplici. In alcuni modelli di RN alcune singole unità elementari (note in letteratura come *grandmother cells*) rappresentano una specifica caratteristica o un determinato concetto; più comunemente i singoli neuroni artificiali sono unità astratte il cui stato di attivazione

concorre alla formazione di *pattern* di attività distribuiti su tutta la rete che rappresentano l'informazione.

TOPOLOGIA DELLE RETI NEURALI

Le **figure 3** (ripresa da [5]) e **4** (rispettivamente una rete Back-propagation ed una rete di Hopfield) rappresentano le due fondamentali topologie di interconnessione delle reti neurali: *feed-forward* e *feed-back*.

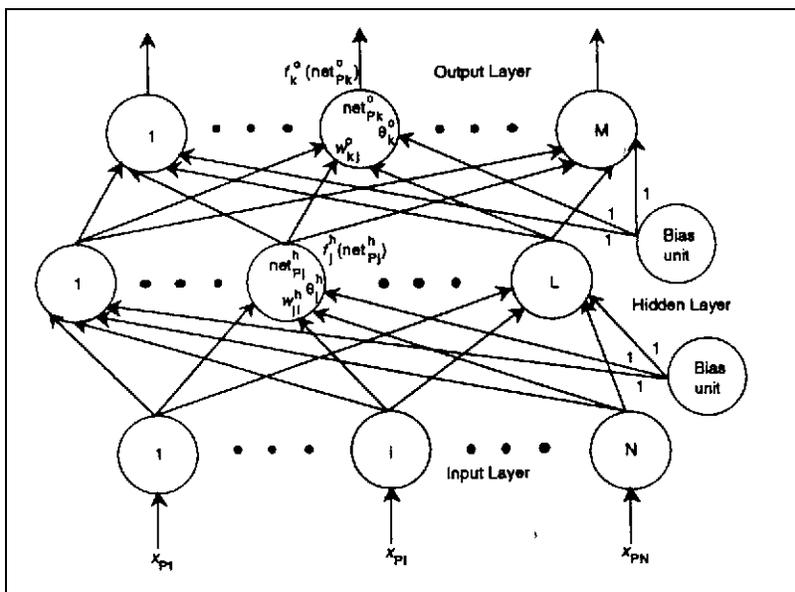


Figura 3 - topologia feed-forward di una rete Back-propagation (da: J. Freeman, "Simulating Neural Networks with Mathematica", Addison Wesley, 1994)

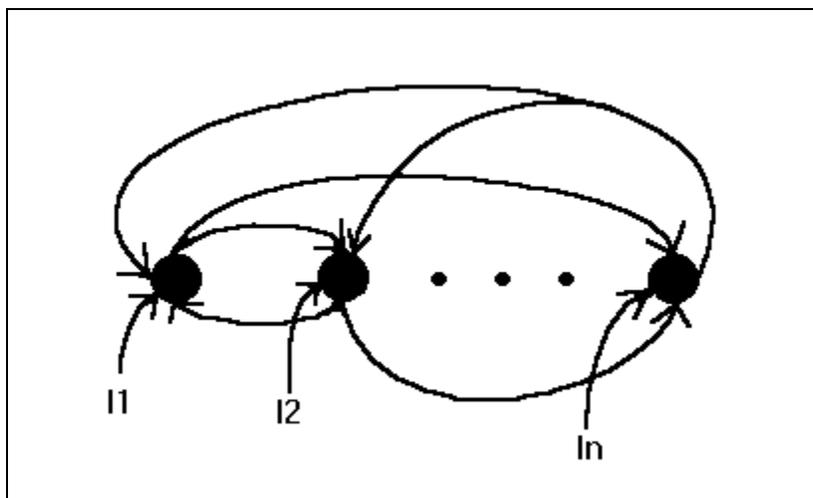


Figura 4 - topologia feed-back di una rete di Hopfield

Le reti *feed-forward* sono spesso organizzate gerarchicamente: l'informazione fornita come *input* viene "filtrata" propagando i segnali che la rappresentano attraverso una successione di livelli (*layer*) composti da unità che presentano esclusivamente connessioni di ingresso con il livello precedente e connessioni di uscita con il livello successivo. Se le connessioni tra unità

appartenenti a livelli successivi non sono complete (connessione parziale) allora ad alcune unità del livello di *output* (il livello in cui si formano i *pattern* di attività che rappresentano la "soluzione" calcolata dalla rete) sarà associato un insieme più o meno ampio di unità del livello di *input*: per analogia con alcuni sistemi sensoriali biologici questo insieme viene definito "campo recettivo" dell'unità. Molte reti neurali della "prima generazione" - come le reti neurali di McCulloch & Pitts, il Perceptron di Rosenblatt, i modelli Adaline e Madaline di Widrow - fino alle famose *Back Propagation Networks* (BPN) sono reti di tipo *feed-forward*.

Le reti o i moduli di rete di tipo *feed-back* presentano interconnessioni direttamente o indirettamente ricorsive in relazione alla singola unità o al livello cui l'unità appartiene: in questo caso la "soluzione" determinata dalla rete (completamente connessa) è lo stato attrattore - cioè la configurazione stabile e distribuita di attività - in cui la rete "rilassa" al termine di una successione di iterazioni (tempocontinue o tempodiscrete) innescata dai valori (*pattern*) forniti come *input*. Un caso molto importante di interconnessione ricorsiva è la cosiddetta "inibizione laterale" (*on-center/off-surround*) rappresentata nella **figura 5**: questa organizzazione, in cui l'attività di un'unità si rinforza a spese dei livelli di attivazione delle unità limitrofe secondo la topologia della rete, rappresenta infatti, in presenza di una limitazione globale dell'attività complessiva (normalizzazione "energetica"), il prototipo della competizione tra unità su cui si fonda il funzionamento di molti recenti modelli di RN.

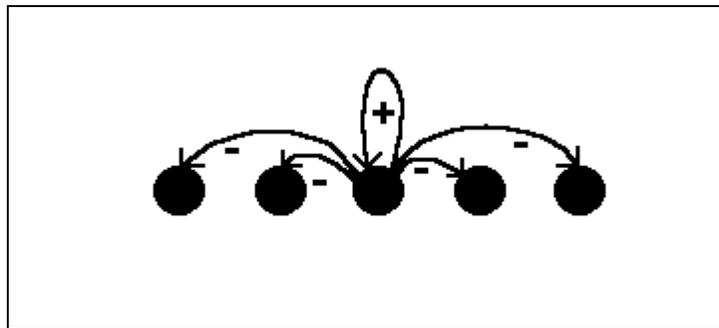


Figura 5 - topologia competitiva on-center/off-surround

ELABORAZIONE DELL'INFORMAZIONE NELLE RETI NEURALI

Se il paradigma dell'elaborazione convenzionale dell'informazione è quello della macchina di Von Neumann - serialità e sequenzialità, controllo centralizzato della computazione, rappresentazione simbolicamente codificata della realtà - il paradigma delle RN è: elaborazione parallela, distribuita e codifica "per analogia" delle informazioni. La capacità delle RN di "risolvere" i problemi rappresentandone ed elaborandone i dati e i vincoli in forma "analogica" (si presti attenzione: in questo caso il termine non ha l'usuale significato di continuo o di non digitale) e intrinsecamente parallela, anziché per mezzo di una formalizzazione simbolica, le rende particolarmente adatte per la ricerca approssimata di soluzioni quasi-ottimali di complessi problemi di ottimizzazione come quello, molto famoso, del "commesso viaggiatore" (TSP: *Travelling Salesman Problem*) che deve visitare, in un ordine qualsiasi, tutte le città comprese in una lista percorrendo il tragitto complessivamente più corto (o, in generale, meno costoso). La **tabella 1** (ripresa e tradotta da **[6]**) illustra una possibile interpretazione concettuale e neurale della definizione matematica di RN come sistema parallelo e distribuito di computazione.

Corrispondenze tra il mondo matematico delle RN e i mondi neurale e concettuale		
NEURALE	MATEMATICO	CONCETTUALE
neuroni	unità	ipotesi
frequenza di emissione	attivazione	grado di confidenza
propagazione della depolarizzazione	propagazione della attivazione	propagazione della confidenza: inferenza
sinapsi	connessione	relazione concettuale o inferenziale
eccitazione/inibizione	coefficienti trasmissivi positivi/negativi	relazioni inferenziali positive/negative
additività approssimativa della depolarizzazione	somma dei segnali di inputs	additività approssimativa dell'evidenza
soglia di emissione	soglia per la propagazione dei segnali di attivazione	indipendenza dalle informazioni irrilevanti
limitazione del range dinamico	funzione di attivazione "sigmoideale"	limitazione della risultanza computazionale (processing strength)

Tabella 1 - interpretazione concettuale e neurale della definizione matematica di RN come sistema parallelo e distribuito di computazione (da: P. Smolensky, "Neural and Conceptual Interpretation of PDP Models", in: J. McClelland & D. Rumelhart, "Parallel Distributed Processing" Vol. 2, MIT Press, 1988)

SINERGIA E COOPERAZIONE

Le proprietà "emergenti" delle RN sono originate dalle interazioni non-lineari delle singole unità: sono caratteristiche sinergiche della rete non inferibili dal comportamento dei singoli elementi che la compongono. Le unità interconnesse "cooperano" alla realizzazione di un comportamento globale sulla base di azioni aventi effetti esclusivamente (o quasi) locali.

MEMORIA E CODIFICA DELL'INFORMAZIONE

Nelle RN Carpenter e Grossberg [4] distinguono una memoria a "breve termine" (STM: *Short Term Memory*) costituita dall'attività globale - indotta dalle informazioni presentate come *input* sensoriale - distribuita nelle singole unità e una memoria a "lungo termine" (LTM: *Long Term Memory*) costituita dai coefficienti trasmissivi che amplificano positivamente (sinapsi eccitatorie) o negativamente (sinapsi inibitorie) la propagazione dei segnali nella rete.

La rappresentazione della conoscenza - o, più propriamente, delle informazioni - in una rete neurale può presentare una codifica localizzata (attivazione di una unità specifica o valore di un determinato coefficiente trasmissivo) o, con modalità più consona alle caratteristiche delle RN, distribuita (configurazioni spazio-temporali dei valori di attivazione o dei coefficienti "sinaptici").

Uno dei tradizionali campi di applicazione delle RN sono le cosiddette "memorie associative": dopo una prima fase di apprendimento una RN che implementa una memoria associativa è in grado di fornire l'elemento mancante di una coppia di *pattern* (memorie etero-associative) o la versione corretta di un *pattern* deformato o degradato (memorie auto-associative). Generalizzando le

funzionalità delle RN impiegate come memorie associative è possibile realizzare veri e propri riconoscitori di *pattern*.

DINAMICA DELLE RETI NEURALI

Nei primi anni '80 Hopfield ha introdotto, per la descrizione della dinamica globale delle RN ricorsive e completamente connesse, una funzione "energia" avente per dominio le attività delle unità e i coefficienti delle interconnessioni ed ha dimostrato che la dinamica della rete "rilassa" spontaneamente in uno stato attrattore corrispondente ad un minimo (locale o globale) della superficie descritta dalla funzione "energia" (di cui la **figura 6** è un esempio del tutto ipotetico).

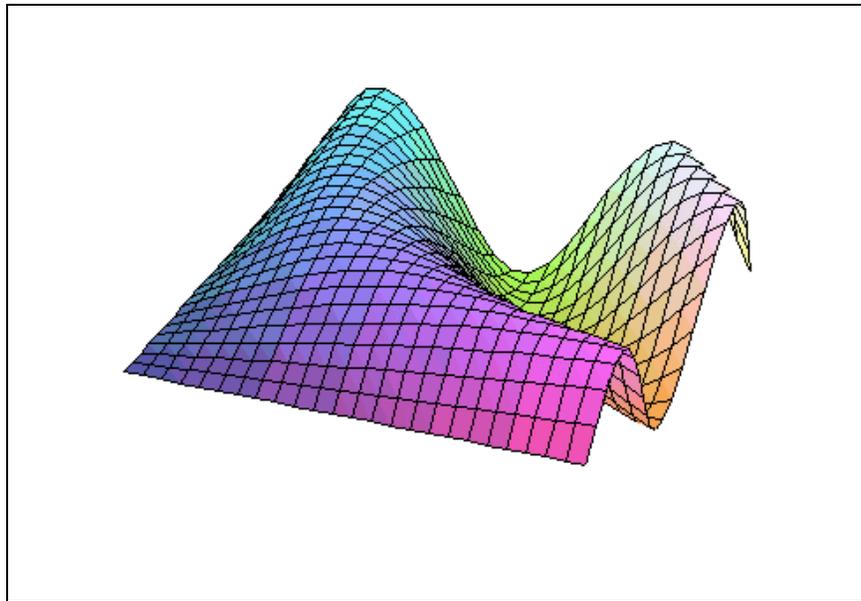


Figura 6 - esempio ipotetico della superficie descritta dalla funzione "energia" di una rete neurale ricorsiva

Allo stato di equilibrio stabile è associata una configurazione distribuita dei livelli di attività delle unità compatibile con l'*input* attuale e con i coefficienti trasmissivi determinati o appresi in precedenza: se questi vincoli rappresentano i requisiti della soluzione di un problema di ottimizzazione è possibile "risolverlo per analogia" (e non tramite un calcolo simbolico-numerico) ed in modo intrinsecamente parallelo. La soluzione "ottima" del problema è sempre associata al minimo globale della superficie della funzione energia, ma la rete può rilassare anche in uno stato corrispondente ad un minimo locale: esistono alcune tecniche di rilassamento stocastico (*simulated annealing* e *Boltzmann machine*) che permettono di avviare, almeno in parte, all'inconveniente pur non garantendo in ogni caso una soluzione globalmente ottima.

APPRENDIMENTO ED AUTO-ORGANIZZAZIONE COMPETITIVA

Nel testo *Machine Learning* del 1985 Carbonell, Michalski e Mitchell individuano le seguenti strategie di apprendimento per un sistema artificiale:

- per implementazione diretta della conoscenza (programmazione);
- per istruzione;
- per analogia;
- per esempi;
- per osservazione e scoperta.

Alcune RN sono realmente in grado di apprendere "per analogia, per esempi e per scoperta guidata dall'osservazione": vedremo nella seconda parte dell'articolo un modello particolarmente significativo sotto questo aspetto, il modello ART di Grossberg e Carpenter.

In generale la "plasticità" adattiva delle reti neurali è data dalla possibilità di modificare i coefficienti trasmissivi delle interconnessioni e, eventualmente, i valori di soglia delle singole unità. Possiamo suddividere i modelli di RN in due categorie: le reti in cui l'apprendimento è controllato da un supervisore esterno (*teacher*) che fornisce una valutazione dell'errore (è questo, per esempio, il caso delle *Back-propagation networks*) e le reti che si auto-organizzano senza alcun intervento esterno se non, eventualmente, per distinguere la fase di apprendimento da quella di "riconoscimento". Il rinforzo (positivo o negativo) costituito da una valutazione esterna alla RN dell'errore commesso è interpretabile come una forma di "condizionamento operante"; una RN in grado di "apprendere" anche senza l'ausilio di un supervisore esterno è certamente compatibile in misura maggiore con le comuni osservazioni della psico-biologia aventi per oggetto i processi di apprendimento.

Nelle RN che si auto-organizzano la procedura di apprendimento è spesso una variazione di una "regola" ipotizzata da Hebb nel 1949 per i sistemi nervosi biologici: si tratta di una forma di condizionamento auto-referenziale e locale per cui i coefficienti "sinaptici" di una rete neurale artificiale si modificano in funzione dell'intensità dei segnali trasmessi. L'auto-organizzazione è sempre una conseguenza di forme di competizione localizzate come l'inibizione laterale e le limitazioni imposte sia ai livelli di attività delle unità che alla disponibilità della risorsa "coefficiente sinaptico".

Una breve storia delle memorie associative

Le RN che implementano una memoria associativa (CAM: *Context Addressable Memory*) sono spesso impiegate anche come riconoscitori e classificatori di *pattern*. Una linea di ricerca consolidata da tempo e frequentemente impiegata in campo applicativo ha dato origine a RN in cui l'apprendimento è supervisionato esternamente con una procedura di propagazione e correzione dell'errore che, vista sotto l'aspetto di un'ottimizzazione della risposta, è spesso riconducibile al classico metodo del gradiente discendente. Sono di questo tipo molti classici modelli di RN come il Perceptron di Rosenblatt (che elabora *inputs* di tipo binario), le reti Adaline e Madaline di Widrow e le diffuse *Back-propagation networks*. Un diverso filone di ricerca ha portato a sviluppare RN che si auto-organizzano anche in assenza di supervisione esterna e nelle quali emerge un comportamento globale cooperativo fondato sulla competizione locale tra le unità della rete: appartengono a questa categoria i modelli di Kohonen (lineari, con fasi di apprendimento e di riconoscimento distinte) e di Grossberg (non-lineari, con fasi di apprendimento e di riconoscimento non necessariamente distinte). In particolare il modello ART (*Adaptive Resonance Theory*) di Grossberg e Carpenter deve alcune delle sue interessanti caratteristiche ad una regola di attivazione delle singole unità della rete che non è semplicemente additiva, ma di tipo *shunting*, per cui il livello di attività viene mantenuto entro limiti inferiore e superiore prefissati.

Il grafico della **figura 7** (ripreso da **[1]**) è puramente indicativo: intende confrontare alcuni modelli di RN valutandone qualitativamente la "validità come modello psico-cognitivo e neurobiologico" e la "validità come applicazione o come sistema di computazione".

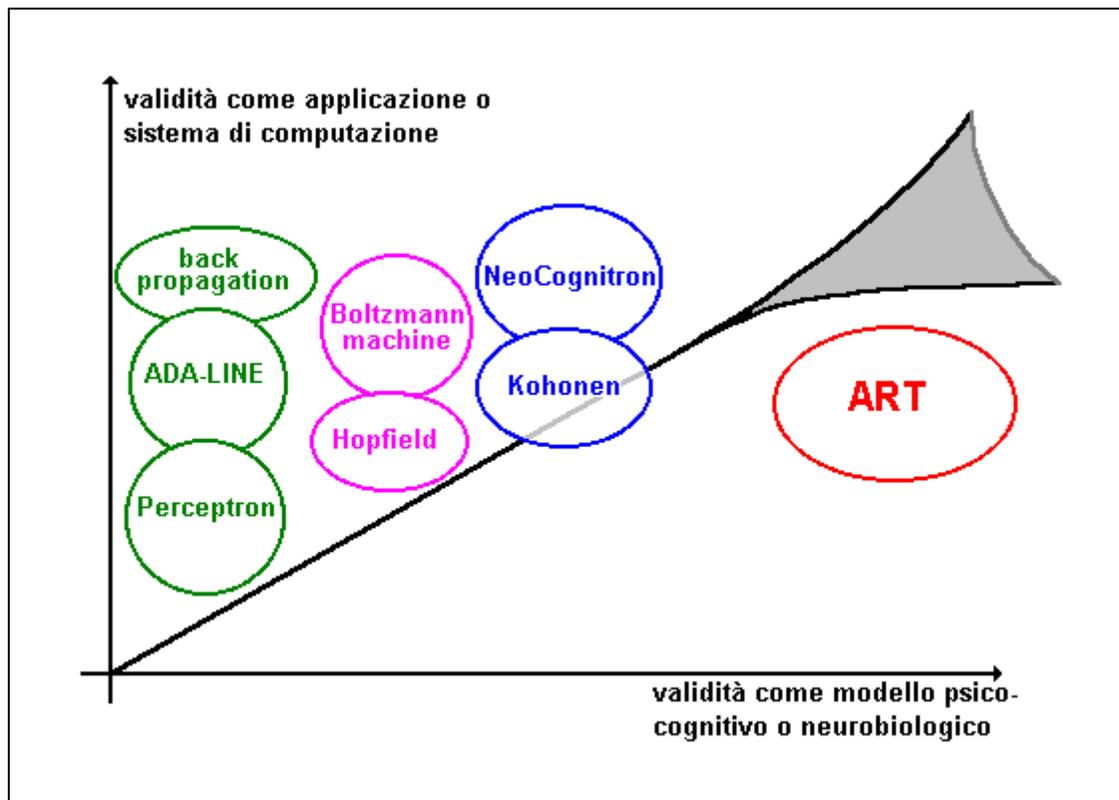


Figura 7 - confronto qualitativo tra vari modelli di RN (da: G. Meini, "Reti neurali: modelli biologici o sistemi di computazione?", Università statale di Pisa, Giugno 1991)

Introduzione al modello ART

Il modello ART - del quale esistono molte e diverse implementazioni (ART1, ART2, ART3, *fuzzyART*, *ARTmap*, ...) - è stato sviluppato da Carpenter e Grossberg per superare alcune delle macroscopiche discrepanze esistenti tra molti modelli di reti neurali artificiali e il processo di auto-organizzazione dei sistemi nervosi biologici, fondato su interazioni attive in tempo reale e in presenza di rumore con un ambiente esterno tipicamente non stazionario. Il paradigma di apprendimento delle reti ART non ricorre ad un insegnante onnisciente esterno e non distingue una fase di apprendimento (plasticità adattiva) da una diversa e successiva fase di esclusivo riconoscimento. Per una comparazione tra il paradigma ART e le modalità di apprendimento di altri modelli di RN si veda la **tabella 2** ripresa da [4].

Confronto del modello ART con altre modalità di apprendimento	
Architettura ART	Caratteristiche di apprendimento di architetture alternative
apprendimento real-time (on-line)	apprendimento lab-time (off-line)
ambiente non-stazionario	ambiente stazionario
auto-organizzazione (non supervisionata)	risposte corrette fornite da un insegnante (teacher) esterno (supervisione)
auto-stabilizzazione della memoria in risposta ad un numero arbitrario di inputs	catastrofe di capacità in risposta ad un numero arbitrario di inputs
uso effettivo di tutta la capacità di memoria	uso parziale della capacità di memoria
mantenimento della plasticità in ambiente ignoto	interruzione esterna della plasticità al fine di prevenire catastrofi di capacità
apprendimento di aspettative top-down interne	"costi" imposti dall'esterno
apprendimento regolato da un focus attenzionale attivo	apprendimento passivo
apprendimento lento o veloce	apprendimento lento o catastrofe di oscillazione
apprendimento in fase di match approssimativo	apprendimento in fase di mismatch
la superficie della funzione energia è globalmente riorganizzata in base ad un procedimento auto-regolativo di validazione di ipotesi (hypothesis testing)	aggiunta di rumore per perturbare il sistema all'esterno dei minimi locali di una superficie fissa della funzione energia
ricerca adattiva veloce per il match migliore	albero di ricerca
accesso diretto e rapido alla codifica degli eventi familiari	il tempo di riconoscimento cresce con la complessità della codifica
criterio di errore variabile (parametro di vigilanza) per fissare il livello di approssimazione di un codice di riconoscimento in risposta al feedback ambientale	criterio fisso di errore in risposta al feedback ambientale
proprietà scalabili arbitrariamente	proprietà che si deteriorano con l'incremento della capacità del sistema

Tabella 2 - comparazione tra il paradigma ART e le modalità di apprendimento di altri modelli di RN (da: G. Carpenter & S. Grossberg, "Self-Organizing Neural Networks Architectures for Real-Time Adaptive Pattern Recognition", in: H. Haken (ed.), "Neural and synergetic computers", Springer-Verlag)

Nel modello ART il riconoscimento è inteso, in accordo con la psicologia della Gestalt, come "percezione" di uno stato interno di "risonanza" tra aspettativa ed informazione sensoriale: il

codice "cognitivo" che viene associato ai *pattern* presentati alla rete come *input* realizza una classificazione in categorie basata sulla presenza di regolarità (generalizzazione) ed è, in questo senso, insensibile al rumore. Nei modelli di RN che apprendono propagando informazioni di correzione fornite da un insegnante esterno l'errore viene stimato come differenza tra comportamento effettivo e comportamento atteso; nel modello ART invece la risonanza tra aspettativa e *input* viene computata come somma. A questo scopo una tipica architettura ART - come il modello ART1 della **figura 8** (ripresa da [4]) - è organizzata su due livelli (F_1 e F_2) che, diversamente dal caso del filtro adattivo della figura 2, sono connessi in entrambe le direzioni (*feed-back*): i *pattern* sono forniti come *input* (binari nel caso del modello ART1, "analogici" nel modello ART2) alle unità del livello F_1 e la "risposta" della rete consiste, dopo una veloce fase di riconoscimento e/o di apprendimento, nell'attivazione di un'unica unità del livello F_2 alla quale corrisponde la categoria (codice) del *pattern*.

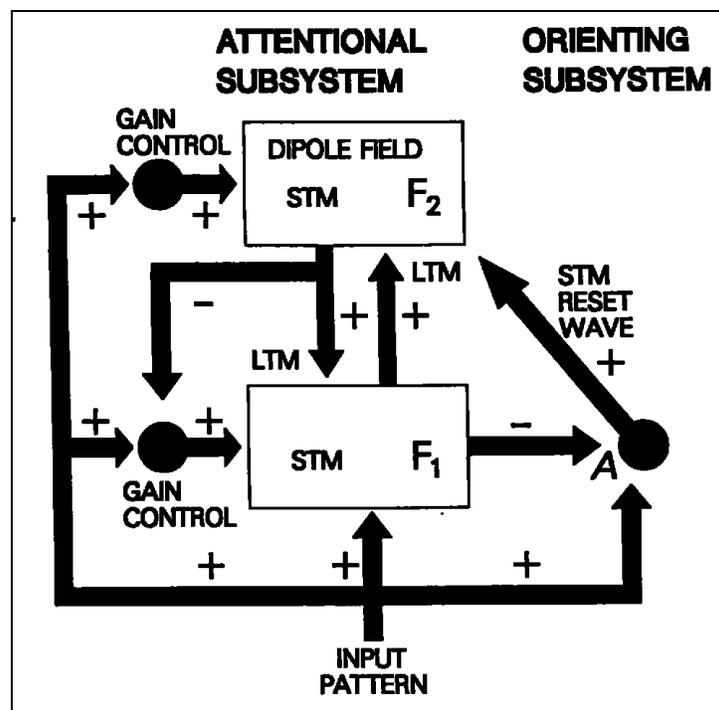


Figura 8 - architettura ART1 (da: G. Carpenter & S. Grossberg, "Self-Organizing Neural Networks Architectures for Real-Time Adaptive Pattern Recognition", in: H. Haken (ed.), "Neural and synergetic computers", Springer-Verlag)

Alla trasmissione *bottom-up* (da F_1 a F_2) delle informazioni sensoriali corrisponde una trasmissione *top-down* (da F_2 a F_1) dell'aspettativa interna: la somma dei due segnali contribuisce a creare - rinforzando una codifica già nota o apprendendone una nuova - una condizione di risonanza adattiva corrispondente al riconoscimento percettivo del *pattern* presentato come *input*. Il livello F_2 della rete ART1 implementa una forma di apprendimento competitivo in tempo reale nota come WTA (*Winner Take All*) che è realizzata per mezzo di un'organizzazione topologica di tipo *on-center/off-surround* e che genera una codifica localizzata dei *pattern* classificati. Questa estrema forma di "compressione" può essere resa più graduale adottando codifiche distribuite: in ogni caso si ottiene una enfattizzazione delle caratteristiche salienti del *pattern* come risultato di un processo di soppressione del rumore e di "aumento del contrasto".

Come è stato già ricordato, Cohen e Grossberg hanno dimostrato che il ricorso a funzioni di attivazione delle unità di tipo *shunting* - rispetto a funzioni semplicemente additive come avviene,

per esempio, nel modello BAM (*Bidirectional Associative Memory*) di Kosko - consente di risolvere il problema della "saturazione da rumore" realizzando un filtro adattivo e regolabile ("controllo automatico del guadagno"). La normalizzazione dell'attività totale che si ottiene in questo modo è interpretabile come un principio di conservazione ed è in accordo con la classica descrizione fisiologica della membrana delle cellule nervose che è valsa a Hodgkin e Huxley il premio Nobel per la medicina. In particolare l'adozione di una funzione di attivazione di tipo "sigmoidale" (per il grafico si veda uno dei dettagli della **figura 1**) comporta l'esistenza di una soglia selettiva dinamica di soppressione del rumore e di compressione ed aumento del contrasto dei *pattern*.

Tutti le reti basate sul modello ART risolvono uno dei problemi fondamentali e caratteristici delle RN: il dilemma stabilità/plasticità. Un comportamento stabile rispetto ad eventi irrilevanti e plastico rispetto ad eventi significativi può infatti essere ottenuto solo per mezzo del *feedback* in tempo reale tra la presente "visione" sensoriale e lo stato di aspettativa basato sull'esperienza passata ("inferenza inconscia") che consente la percezione. La connessione bidirezionale, e l'attivazione ricorsiva che ne consegue, dei livelli F_1 e F_2 delle reti ART permette di evitare situazioni di instabilità - anche catastrofiche - che si verificano, in particolari condizioni operative legate al processo di apprendimento, in altri modelli di RN.

Una introduzione dettagliata ai modelli ART (ART1 e ART2 in particolare) può essere trovata, oltre che in [4], anche in [7] e [8]. Come si è visto una rete ART costituisce un sistema di classificazione in categorie create sulla base di regolarità presenti nei *pattern* forniti come *input*: è comunque possibile implementare una memoria associativa connettendo, nelle due direzioni, le unità corrispondenti dei livelli F_2 di due moduli ART, come in **figura 9** (ripresa da [7]).

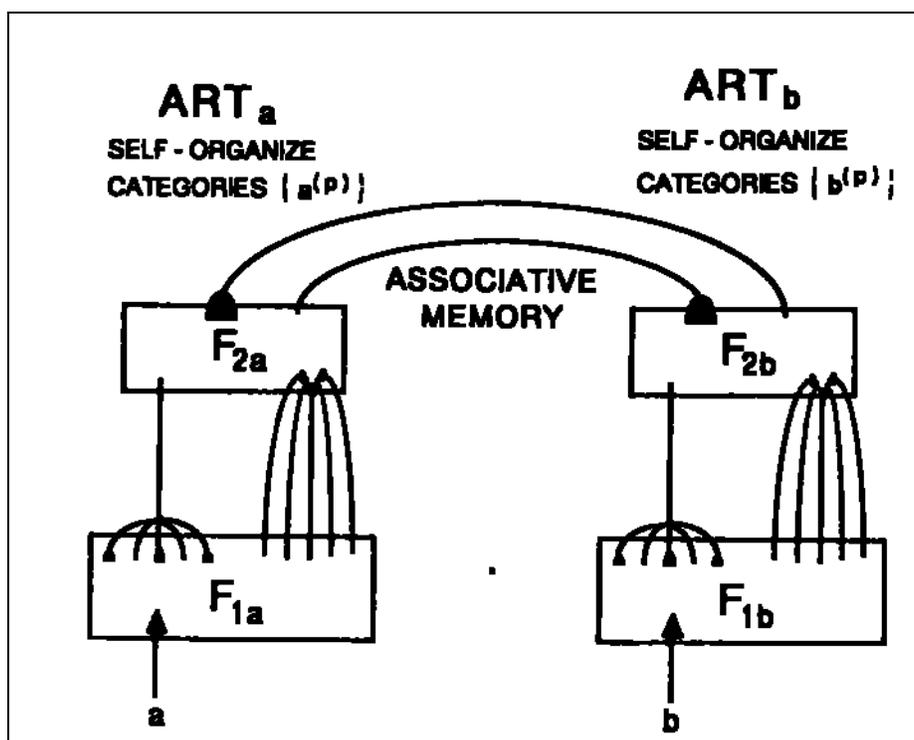


Figura 9 - una memoria associativa composta da due moduli ART (da: G. Carpenter & S. Grossberg, "Self-Organizing Neural Networks Architectures for Real-Time Adaptive Pattern Recognition", in: H. Haken (ed.), "Neural and synergetic computers", Springer-Verlag)

Alcuni dettagli della rete ART1

La **figura 8** rappresenta lo schema concettuale della rete ART1.

Come è già stato sottolineato questa rete neurale è stata progettata per esibire un comportamento adattivo ed auto-organizzato nella classificazione (codifica) e nel riconoscimento dei *pattern* forniti come *input* (vettori binari). In particolare ART1, pur essendo stabile rispetto alle informazioni apprese nel passato, si mantiene plastica rispetto ad eventuali novità da apprendere nel presente. Si è già visto che il "dilemma stabilità/plasticità" viene risolto da una forma di "aspettativa" interna degli eventi esterni da parte del sottosistema attenzionale della rete: il riconoscimento di un *pattern* coincide infatti con uno stato di "risonanza" tra segnali STM che si propagano *bottom-up* dal livello di *input* al livello di codifica e segnali STM che si propagano *top-down* dal livello di codifica a quello di *input*. La propagazione dei segnali nelle due direzioni è influenzata dai coefficienti LTM continuamente modificati dall'apprendimento: la codifica WTA di un vettore binario viene rinforzata se questo è assimilato dalla rete ad una informazione già nota dalla propria esperienza passata, o appresa nel caso si tratti di una informazione interpretabile come novità. Il livello F_2 del sottosistema attenzionale è quindi strutturato come un filtro adattivo competitivo (topologia *on-center/off-surround*, codifica *Winner Take All*) finalizzato alla classificazione (categorizzazione percettiva) dei *pattern* dettagliatamente rappresentati dall'attività distribuita delle unità sensoriali del livello F_1 . Le **figure 10 e 11** rappresentano, rispettivamente, le connessioni delle singole unità dei livelli F_1 e F_2 .

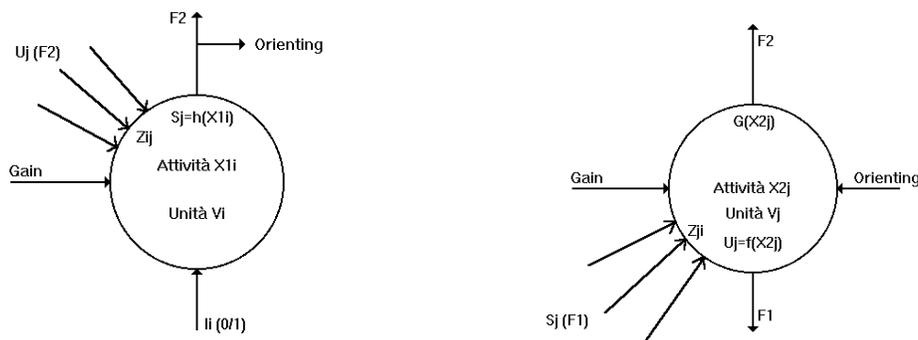


Figure 10 e 11 – connessioni delle unità del livello F_1 e F_2 , rispettivamente, di una rete ART1

Il *feed-back* di informazioni tra i 2 livelli che compongono il sottosistema attenzionale dà origine ad un ciclo di validazione delle ipotesi interne rispetto alle informazioni esterne (si veda la **figura 12** ripresa da [4]): in caso di discordanza tra segnali STM *top-down* e *bottom-up* (**figura 12b**) in luogo dello stato di risonanza e del conseguente rinforzo o apprendimento "sinaptico" delle "tracce mnemoniche" LTM si ha, da parte del sottosistema orientativo, la generazione di un segnale di *reset* (**figura 12c**) che inibisce l'unità "vincente" del livello F_2 che ha causato la situazione di *mismatch* permettendo, in questo modo, al livello F_2 di selezionare una codifica (ipotesi) alternativa (**figura 12d**) che fornisca un *match* sufficientemente approssimato con il vettore di attivazione del livello F_1 .

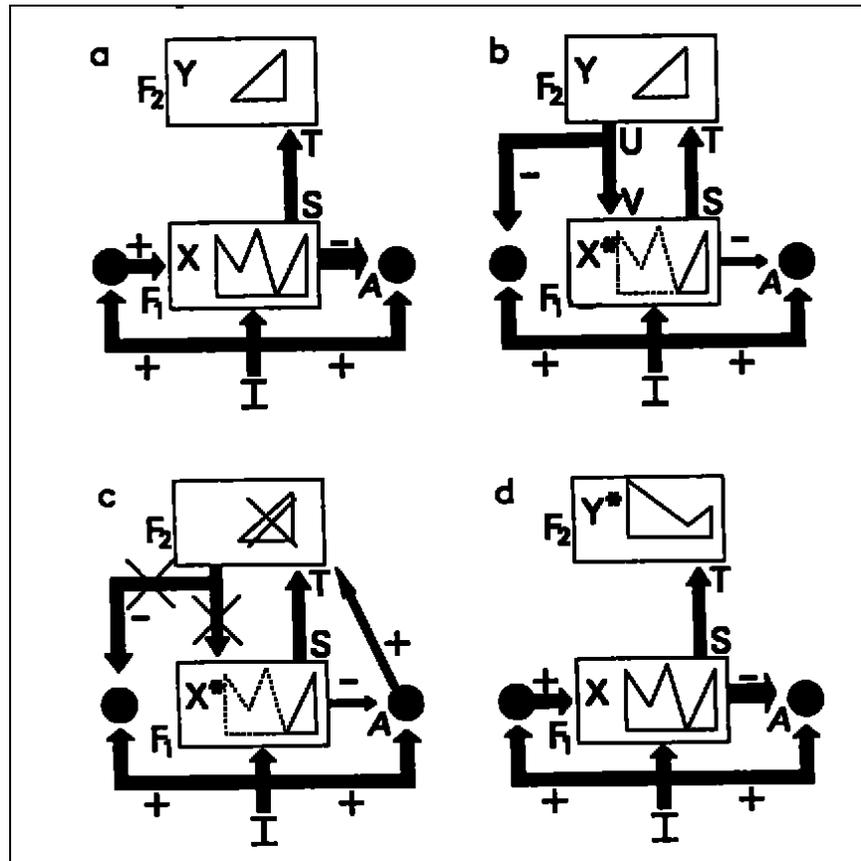


Figura 12 - ciclo di validazione delle ipotesi interne rispetto alle informazioni esterne in una rete ART (da: G. Carpenter & S. Grossberg, "Self-Organizing Neural Networks Architectures for Real-Time Adaptive Pattern Recognition", in: H. Haken (ed.), "Neural and synergetic computers", Springer-Verlag)

Il sottosistema orientativo si comporta in definitiva come un rivelatore di novità modulato dal "parametro di vigilanza" - eventualmente controllabile dall'esterno - il cui valore è compreso tra 0 e 1: per valori del parametro prossimi a 1 per piccole differenze dei vettori di *input* vengono costituite nuove categorie di classificazione, mentre per valori prossimi a 0 i *pattern* sono classificati in grandi categorie approssimative. Si noti che, nonostante la sequenzialità del meccanismo di *reset* e del ciclo di *hypothesis testing*, la ricerca di una codifica risonante è un'attività parallela della rete neurale che termina con un *match* adeguato tra informazione ed aspettativa o con l'apprendimento di un nuovo "codice cognitivo". Diversamente da molti altri modelli di RN i coefficienti appresi LTM dipendono dalle condizioni iniziali e dalla storia delle interazioni con l'ambiente della rete ART e non sono prevedibili a priori per mezzo di un algoritmo. Quale funzione ha il "controllo di guadagno" (*gain control*) del sottosistema attenzionale nell'architettura ART (si veda nuovamente la **figura 8**)? In congiunzione con la cosiddetta regola 2/3 (*2/3 rule*) questo meccanismo, attivo esclusivamente in presenza di una codifica in *output* da parte del livello F_2 , assicura la distinzione, da parte delle unità del livello F_1 , dei segnali di attivazione *bottom-up* da quelli *top-down*. Questa distinzione è infatti necessaria al fine di evitare stati di risonanza in assenza di vettori di *input*, come potrebbe avvenire in architetture composte da più moduli ART interconnessi gerarchicamente. La regola 2/3 stabilisce che una unità del livello F_1 - ciascuna delle quali ha tre fonti di *input*: *bottom-up*, *top-down* e *gain* - si attivi solo e soltanto se 2 di questi 3 ingressi sono attivi. L'applicazione della regola è illustrata, per casi, nella **figura 13** (ripresa da [4]):

- una aspettativa *top-down* inibisce il controllo di guadagno in modo da selezionare, tra tutti i possibili vettori di *input*, solo quelli compatibili con l'aspettativa interna;
- l'attivazione del controllo di guadagno da parte di un *pattern* presente in ingresso permette alle unità del livello F_1 di stimolare una codifica da parte del livello F_2 , iniziando il ciclo di validazione delle ipotesi;
- l'attivazione simultanea di un *pattern bottom-up* e di un *template top-down* inibisce il controllo di guadagno in modo che soltanto le unità del livello F_1 che ricevono segnali da entrambe le fonti permangano attive;
- una inibizione esterna del controllo di guadagno distoglie l'attenzione delle unità sensoriali del livello F_1 .

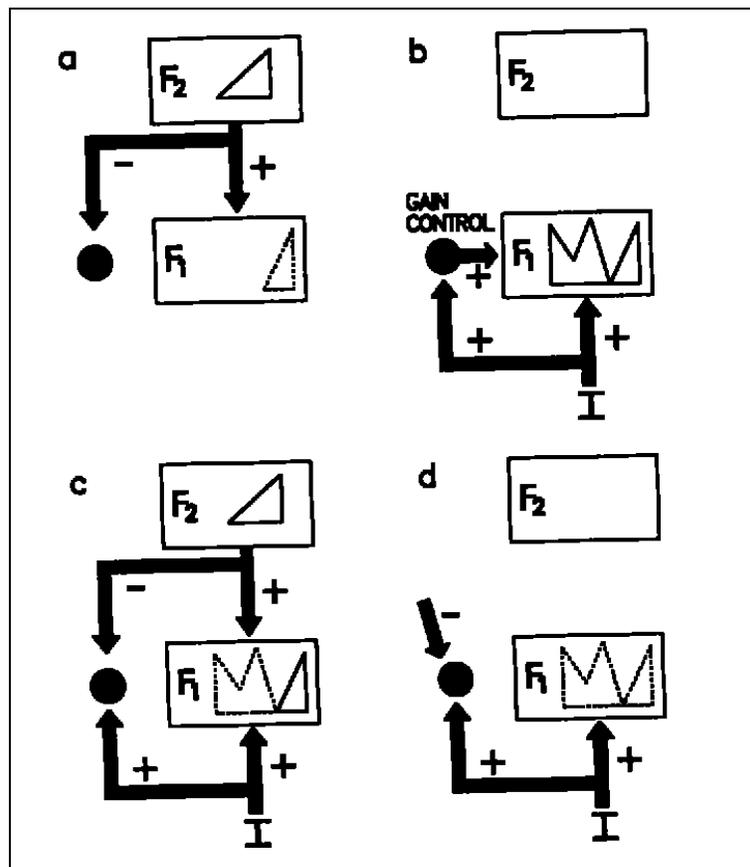


Figura 13 - applicazione della regola 2/3 e controllo del guadagno del sottosistema attenzionale in una rete ART1 (da: G. Carpenter & S. Grossberg, "Self-Organizing Neural Networks Architectures for Real-Time Adaptive Pattern Recognition", in: H. Haken (ed.), "Neural and synergetic computers", Springer-Verlag)

Simulazione della rete ART1 con *Mathematica*[®]

Una rete ART è usualmente implementata con tecnologie proprie dell'elettronica analogica, in modo da avere un funzionamento corrispondente alle equazioni che ne descrivono l'attività come sistema adattivo. Per esempio, una unità del livello F_1 della rete ART ha una funzione di attivazione corrispondente all'integrale della seguente equazione differenziale (A, B, C e D sono parametri costanti, G è il valore binario di *gain*, I la componente del vettore binario di *input*):

$$\frac{dx_{li}}{dt} = -x_{li} + (1 - A_1 x_{li})(I_i + D_1 V_i + B_1 G) - (B_1 + C_1 x_{li}),$$

$$V_i = \sum_j u_j z_{ij}$$

Il passaggio da una descrizione matematica continua ad una procedura algoritmica e discreta di simulazione ha come conseguenza il passaggio da forme di computazione locali, parallele ed asincrone ad una elaborazione globale, seriale (sequenziale) e sincrona. La drastica perdita dell'efficienza computazionale *real-time* viene però compensata, in un'ottica esclusivamente didattica, dalla possibilità di introdurre alcune semplificazioni:

- per implementare la codifica WTA del livello F_2 è sufficiente, anziché implementare uno schema competitivo *center-on/surround-off*, scegliere l'unità avente grado di attivazione maggiore;
- la modifica dei coefficienti trasmissivi (apprendimento) non deve essere fondata sulle diverse costanti di tempo delle equazioni differenziali STM e LTM, ma può essere limitata alla situazione di risonanza;
- il meccanismo di controllo del guadagno e la regola 2/3 possono essere ignorati;
- la funzione di uscita di tutte le unità della rete può consistere nel risultato binario (0/1) di un operatore di soglia (*threshold*).

In definitiva una procedura di simulazione per la rete ART1 può essere così sintetizzata (cfr. [5]):

- 1) *input* di un *pattern* (vettore binario) al livello F_1 ;
- 2) trasmissione *bottom-up* dei segnali di *output* del livello F_1 al livello F_2 (moltiplicazione per i coefficienti w_{ij});
- 3) competizione WTA del livello F_2 : l'unità vincente V^j è l'unica attiva;
- 4) trasmissione *top-down* dei segnali di *output* del livello F_2 al livello F_1 (moltiplicazione per i coefficienti v_{ji});
- 5) confronto, in base al valore del parametro di vigilanza, tra *pattern bottom-up* e *template top-down*: in caso di concordanza (risonanza) si procede con la modifica dei coefficienti (apprendimento) e si prosegue con un nuovo vettore di *input* (1), mentre nel caso di discordanza si disabilita l'unità attiva V^j del livello F_2 (*reset*) e si inizia il ciclo di validazione delle ipotesi (2).

Per analizzare la fase del confronto tra *pattern* e *template* definiamo la magnitudine di un vettore \mathbf{X} come $|\mathbf{X}| = \sum_i x_i$ (nel caso di un vettore binario la magnitudine è data dal numero delle componenti diverse da 0) e il vettore \mathbf{S} di *output* del livello F_1 come:

$$\mathbf{S} = \begin{cases} \mathbf{I}, \overline{F_2} \\ \mathbf{I} \cap \mathbf{V}^j, F_2 \end{cases}$$

cioè uguale al vettore di *input* \mathbf{I} se il livello F_2 è inattivo e uguale all'intersezione tra il *pattern* \mathbf{I} e il vettore *template* propagato dall'unità vincente \mathbf{V}^j del livello F_2 altrimenti. La condizione di *matching* è data dalla seguente relazione:

$$\rho \leq \frac{|\mathbf{S}|}{|\mathbf{I}|}$$

In questo caso si ha risonanza ed avviene l'apprendimento relativo ai soli coefficienti trasmissivi delle connessioni *bottom-up* e *top-down* che coinvolgono l'unità vincente \mathbf{V}^j del livello F_2 :

$$v_{ij} = \begin{cases} 1, u_i \\ 0, u_i \end{cases}$$

$$w_{ji} = \begin{cases} \frac{L}{L-1+|S|}, u_i \\ 0, u_i \end{cases}$$

dove L è un parametro costante e la distinzione è tra unità u_i attive o disattive.

Il listato pubblicato in appendice è un *package* per *Mathematica*[®] che simula una rete ART1: una descrizione dettagliata del codice sorgente si trova nel testo di James Freeman [5] che comprende anche un programma di simulazione per il più complesso modello ART2. Il programma di simulazione (**art1**) rappresenta i livelli F_1 e F_2 come liste di unità aventi uno specifico valore di attivazione e i coefficienti trasmissivi *bottom-up* e *top-down* per mezzo di matrici (**z12**, **z21**). Oltre alle dimensioni di F_1 e F_2 (**f1dim_**, **f2dim_**) è necessario stabilire da parte dell'utente il parametro di vigilanza (**rho_**) e la lista dei vettori binari di *input* (**inputs_**); tutti gli altri parametri possono essere impostati come segue:

```
a1_=1,
b1_=1.5,
c1_=5,
d1_=0.9,
e1_=3 (è il parametro L della funzione di apprendimento);
del1_=0.2,
del2_=0.1.
```

Prima di invocare la procedura di simulazione è necessario inizializzare i coefficienti LTM: a questo scopo il *package* comprende la procedura **art1Init**.

Un semplice esempio di classificazione

Mettiamo alla prova il programma simulando una semplice rete con 5 unità nel primo livello sensoriale e 5 unità nel secondo livello di codifica. Ipotizziamo che la seguente successione di vettori rappresenti la serie temporalmente ordinata dei *pattern* forniti come *input* alla rete: [1,1,0,0,0], [0,0,0,0,1], [0,0,1,1,1], [1,1,1,0,0], [1,0,0,0,0]; in *Mathematica*[®]:

```
in={{1,1,0,0,0}, {0,0,0,0,1}, {0,0,1,1,1}, {1,1,1,0,0}, {1,0,0,0,0}};
```

Per inizializzare i coefficienti *top-down* (**td**) e *bottom-up* (**bu**):

```
{td,bu}=art1Init[5,5,1.5,0.9,3,0.2,0.1];
```

dove i primi due parametri specificano le dimensioni dei livelli della rete. Attiviamo la rete con parametro di vigilanza **0.3** (è l'ultimo dei parametri numerici, i primi due indicano le dimensioni della rete):

```
art1[5,5,1,1.5,5,0.9,3,0.3,td,bu,in];
```

Resonance established on unit 1 with pattern 1

Resonance established on unit 2 with pattern 2
Resonance established on unit 2 with pattern 3
Resonance established on unit 1 with pattern 4
Resonance established on unit 1 with pattern 5
Network not stable
Resonance established on unit 1 with pattern 1
Resonance established on unit 2 with pattern 2
Resonance established on unit 2 with pattern 3
Resonance established on unit 1 with pattern 4
Resonance established on unit 1 with pattern 5
Network stable

La rete ha codificato tutti i 5 *pattern* forniti come *input* utilizzando solo due unità del secondo livello: l'unità 1 per i vettori 1, 4 e 5 e l'unità 2 per i vettori 2 e 3. Si verifica facilmente che ART1 ha "appreso" la distinzione tra destra (unità 2) e sinistra (unità 1)! Ma che cosa accade variando il parametro di vigilanza? Proviamo con **0.7**:

```

in={ {1,1,0,0,0}, {0,0,0,0,1}, {0,0,1,1,1}, {1,1,1,0,0}, {1,0,0,0,0} };
{td,bu}=art1Init[5,5,1.5,0.9,3,0.2,0.1];
art1[5,5,1,1.5,5,0.9,3,0.7,td,bu,in];

```

Resonance established on unit 1 with pattern 1
Resonance established on unit 2 with pattern 2
Reset with pattern 3 on unit 2
Resonance established on unit 3 with pattern 3
Reset with pattern 4 on unit 1
Resonance established on unit 4 with pattern 4
Resonance established on unit 1 with pattern 5
Network not stable
Resonance established on unit 4 with pattern 1
Resonance established on unit 2 with pattern 2
Resonance established on unit 3 with pattern 3
Reset with pattern 4 on unit 4
Reset with pattern 4 on unit 1
Resonance established on unit 5 with pattern 4
Resonance established on unit 1 with pattern 5
Network not stable
Resonance established on unit 4 with pattern 1
Resonance established on unit 2 with pattern 2
Resonance established on unit 3 with pattern 3
Resonance established on unit 5 with pattern 4
Resonance established on unit 1 with pattern 5
Network stable

La rete ha codificato i 5 diversi *pattern* forniti come *input* utilizzando tutte le unità del secondo livello e determinando una distinta codifica per ogni *pattern* in ingresso: ad un valore più elevato del parametro di vigilanza ha corrisposto una classificazione estremizzata. È ovviamente possibile ottenere categorie di generalità intermedia scegliendo opportunamente il valore del parametro di vigilanza, ma la banalità di questo esempio non permette di saggiare adeguatamente le potenzialità delle reti ART1. Ho già abusato dello spazio a mia disposizione, vi invito quindi a sperimentare in proprio la codifica ed il riconoscimento, anche in presenza di rumore casuale, di simboli grafici definiti su di una matrice di $n \times n$ *pixel* (il livello F_1 dovrà essere costituito da $n \times n$

unità, una per ciascun *pixel*): Freeman [5] riporta come esempio l'apprendimento da parte della rete dei caratteri, definiti su di una matrice 5 X 5, corrispondenti alle prime lettere dell'alfabeto.

Una conclusione

Confesso di non essere aggiornatissimo, ma credo che sia ancora valido ciò che ho scritto ormai da alcuni anni [1]:

I limiti delle attuali conoscenze relative al sistema nervoso centrale ed alla corteccia cerebrale in particolare non permettono di realizzare un modello che, pur essendo comunque una astrazione (semplificazione) della realtà, sia compatibile con i dati sperimentali fondamentali; il modello di "elaborazione parallela e distribuita" delle reti neurali coglie una (la?) differenza fondamentale tra i sistemi nervosi biologici e gli schemi di computazione tradizionali (sequenziali e centralizzati).

Nonostante gli approcci tentati da alcuni autori per implementare caratteristiche dei processi cognitivi (per esempio: rappresentazione simbolica e ricorsiva delle informazioni, sequenzialità degli schemi di ragionamento) basandosi su di un sistema connessionistico visto come "microstruttura dei processi cognitivi", lo stato attuale della ricerca non supera la distanza tra il livello psicocognitivo (intelligenza artificiale) e quello neurobiologico (reti neurali).

In alcuni campi di applicazione specifici (acquisizione ed elaborazione di informazioni sensoriali, interazioni senso-motorie in robotica avanzata, memorie associative capaci di generalizzare ed insensibili al rumore, riconoscimento e classificazione di pattern, risoluzione approssimata di complessi problemi di ottimizzazione) le reti neurali ispirate dagli studi neurobiologici sono un sistema di computazione con prestazioni e caratteristiche non offerte dalle tecniche convenzionali e dalla intelligenza artificiale tradizionale.

Quindi, in sintesi:

- *le RN non sono attualmente un buon modello neurobiologico o psicocognitivo; sono un promettente strumento concettuale per le scienze biologiche e psicologiche, le quali, a loro volta, continueranno ad influenzarne l'evoluzione anche nel campo applicativo;*
- *le reti neurali sono una nuova tecnologia ("analogica") per affrontare problemi complessi con una efficienza non raggiunta dalle tecniche simboliche e numeriche;*
- *le reti neurali hanno un ruolo applicativo particolare in robotica avanzata nel controllo dell'interazione senso-motoria anche se non ancora nella rappresentazione interna dell'ambiente esterno nella sua completa complessità, compito per il quale possono eventualmente essere integrate con tecnologie più convenzionali (elettroniche, computazionali e di intelligenza artificiale).*

Riferimenti bibliografici

[1] G. Meini, "Reti neurali: modelli biologici o sistemi di computazione?", Università statale di Pisa, Giugno 1991

[2] V. Cannavacciuolo e P. Costa, "Programmazione evolutiva: le reti neurali", Computer Programming n. 42, Dicembre 1995

[3] D. Rumelhart & J. McClelland, "Parallel Distributed Processing" Vol. 1, MIT Press, 1988

[4] G. Carpenter & S. Grossberg, "Self-Organizing Neural Networks Architectures for Real-Time Adaptive Pattern Recognition", in: H. Haken (ed.), "Neural and synergetic computers", Springer-Verlag

[5] J. Freeman, "Simulating Neural Networks with Mathematica®", Addison Wesley, 1994

[6] P. Smolensky, "Neural and Conceptual Interpretation of PDP Models", in: J. McClelland & D. Rumelhart, "Parallel Distributed Processing" Vol. 2, MIT Press, 1988

[7] G. Carpenter, "Neural Network Models for Pattern Recognition and Associative Memory", Neural Networks, Vol. 2, 1989

[8] S. Grossberg, "Nonlinear Neural Networks: Principles, Mechanisms, and Architectures", Neural Networks, Vol. 1, 1988

Riquadro 1 - reti neurali e invarianza percettiva

Le reti neurali sono spesso impiegate come riconoscitori di *pattern* per la loro relativa insensibilità al rumore. Ma in questo campo di applicazione è anche possibile ottenere, almeno con alcune architetture di RN, una completa indipendenza dalle dimensioni, dalla posizione e dall'orientazione del *pattern* da riconoscere. Nell'elaborazione tradizionale delle immagini l'invarianza di una forma rispetto alle sue trasformazioni geometriche lineari (affinità) si ha applicando la trasformazione spettrale di Fourier-Mellin ad una immagine in cui la figura da riconoscere è stata separata dallo sfondo individuandone il contorno. Nonostante l'evidenza sperimentale di una forma analoga di computazione da parte del sistema nervoso dei mammiferi questa tecnica è molto distante dalle assunzioni della psico-biologia. Il modello di RN noto come "Neocognitron" [si veda: K. Fukushima, "Neocognitron: A hierarchical neural network capable of visual pattern recognition", Neural Networks, Vol. 1, 1988] è strutturato come una rete *feed-forward* e *multi-layered* capace di auto-organizzarsi per mezzo della competizione tra unità e con una modalità di apprendimento non supervisionato esternamente, ma caratterizzata da una fase "plastica" distinta dalla fase di riconoscimento. L'architettura di Neocognitron è di ispirazione biologica - è, di fatto, un'interpretazione operativa del processo con cui il sistema nervoso elabora i segnali portatori di informazione nel percorso dalla retina alla corteccia visiva - e si è dimostrata valida come riconoscitore di *pattern* visuali parzialmente indipendente da trasformazioni spaziali lineari dell'*input*.

Riquadro 2 - reti neurali e *Mathematica*®

Il modello di rete neurale presentato nel testo dell'articolo è stato simulato con un programma per *Mathematica*®. Perché ricorrere a questo ambiente interpretato - ricco di funzionalità, ma non molto efficiente - per lavorare con le RN? Un modello di RN viene generalmente sviluppato per essere implementato con una rete elettronica ed analogica il cui funzionamento sia descritto dallo stesso sistema di equazioni differenziali del modello teorico, ma nella fase di studio non è raro, anche per motivi di flessibilità, che si ricorra a simulazioni *software* con il *computer*. Dato che vantaggi computazionali di una RN nei confronti di una elaborazione tradizionale si concretizzano esclusivamente con la disponibilità di *hardware* specializzato, nel caso di una simulazione "esplorativa" sono senz'altro preferibili la concisione e la semplicità espressiva di un linguaggio di programmazione in cui alcune elaborazioni matematiche complesse siano già implementate come native rispetto ad una relativamente superiore efficienza computazionale. In quest'ottica *Mathematica*® permette di trattare direttamente la matematica continua e differenziale di molte funzioni di attivazione, consente di visualizzare le complesse superfici tridimensionali che descrivono le funzioni "energia" delle RN e rende disponibili operatori discreti - vettoriali e matriciali - per calcolare l'interazione tra *pattern* distribuiti di attivazione e coefficienti trasmissivi della rete. Per esempio, nel caso del filtro adattivo rappresentato nella figura 2 le uscite delle unità v_i del livello F_1 sono connesse alle unità v_j del livello F_2 : ogni connessione ha il proprio coefficiente moltiplicativo "sinaptico" z_{ji} ed ogni unità del secondo livello computa la somma di tutti i propri ingressi. La relazione matematica tra il vettore di *output* \mathbf{X} del livello F_1 e il vettore di *input* \mathbf{Y} del livello F_2 è espressa dalla seguente formula:

$$y_j = \sum_i x_i z_{ji}$$

che, in *Mathematica*[®], può essere semplicemente espressa come $\mathbf{y}=\mathbf{X.Z}$ (*dot product*) invece che con il ciclo necessario con un qualsiasi altro linguaggio di programmazione.

Riquadro 3 - reti neurali ed algoritmi genetici

Che cosa hanno in comune reti neurali ed algoritmi genetici, se non il fatto di essere stati entrambi sviluppati a partire da conoscenze proprie delle discipline biologiche? È in primo luogo notevole (casuale?) che due delle più promettenti e meno tradizionali tecniche di computazione *hardware* e *software* nascano come "modelli" di biologia teorica, ma i legami tra RN e AG non sono limitati alla loro comune origine. Gli AG vengono infatti anche utilizzati per selezionare in base alla loro *fitness* applicativa varianti, qualitative o quantitative, di RN create con i tipici operatori genetici di incrocio e mutazione oppure per ottimizzare in fase di *training* i valori dei coefficienti trasmissivi di una rete (si veda, per un esempio in proposito, l'ultimo capitolo del libro di James Freeman citato nel testo e nella bibliografia dell'articolo).

Ma c'è di più: il premio Nobel per la medicina Gerald Edelman ha proposto - in un famoso scritto del 1987 intitolato *Neural Darwinism* - una teoria della selezione neurale di gruppo. Questo trasferimento del concetto di selezione dalla storia evolutiva filogenetica allo sviluppo ontogenetico del fenotipo modulato dall'informazione ambientale individua i gruppi di neuroni come unità funzionali del sistema nervoso centrale e, in particolare, della corteccia cerebrale (un'ipotesi anatomica e fisiologica è quella delle "colonne neurali corticali" avanzata nel 1977 dai premi Nobel per la medicina David Hubel e Thorsten Wiesel e nel 1978 dallo stesso Edelman in collaborazione con V. B. Mountcastle). Edelman ha sviluppato, insieme ad alcuni collaboratori, complessi modelli computazionali e di simulazione per verificare la plausibilità di questa teoria: si tratta di RN che si auto-organizzano in base ad una particolare forma di competizione tra gruppi di unità finalizzata alla costituzione di "campi neurali recettivi"; la selezione neurale viene inizialmente effettuata a partire dal rumore non organizzato spontaneamente presente nella rete. Le RN di Edelman implementano una forma di apprendimento in tempo reale e non supervisionato alternativa rispetto a quella del modello ART di Carpenter e Grossberg descritto nel testo dell'articolo. Una descrizione più dettagliata è riportata in: G. Reeke Jr., L. Finkel, G. Edelman, "Selective Recognition Automata", pubblicato nell'ottima raccolta di scritti interdisciplinari curata da S. Zornetzer, J. Davis e C. Lau: "An Introduction to Neural and Electronic Networks" (Academic Press, 1990).