


Modelli in ecologia

*Fisici, concettuali,
empirici ed analitici*


sistema reale



astrazione



modello



interpretazione


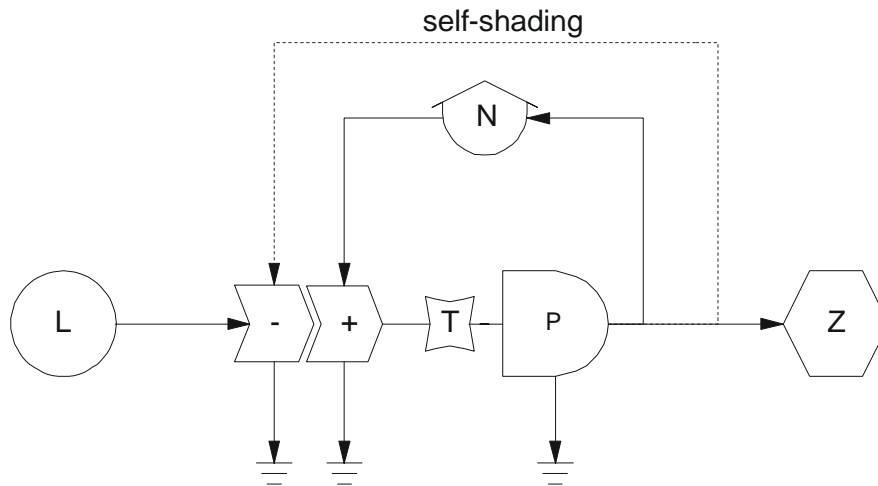
Tipologie di modelli

- **Modelli fisici**
(es. mesocosmi)
- **Modelli concettuali**
(es. modello di Tilman)
- **Modelli analitici**
(es. modello di Lotka-Volterra)
- **Modelli empirici**
(es. modello di Von Bertalanffy)

Modelli fisici



Modelli concettuali



Funzione forzante



Immagazzinamento passivo



Produttore primario



Fattore limitante



Consumatore



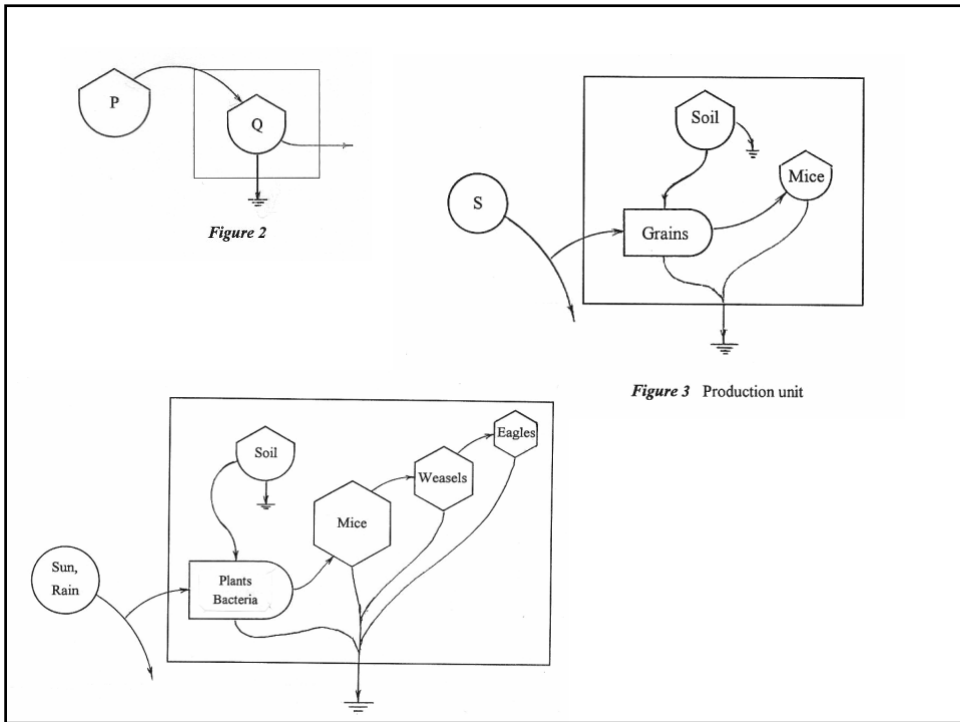

Elemento di controllo



Dissipazione



Flusso




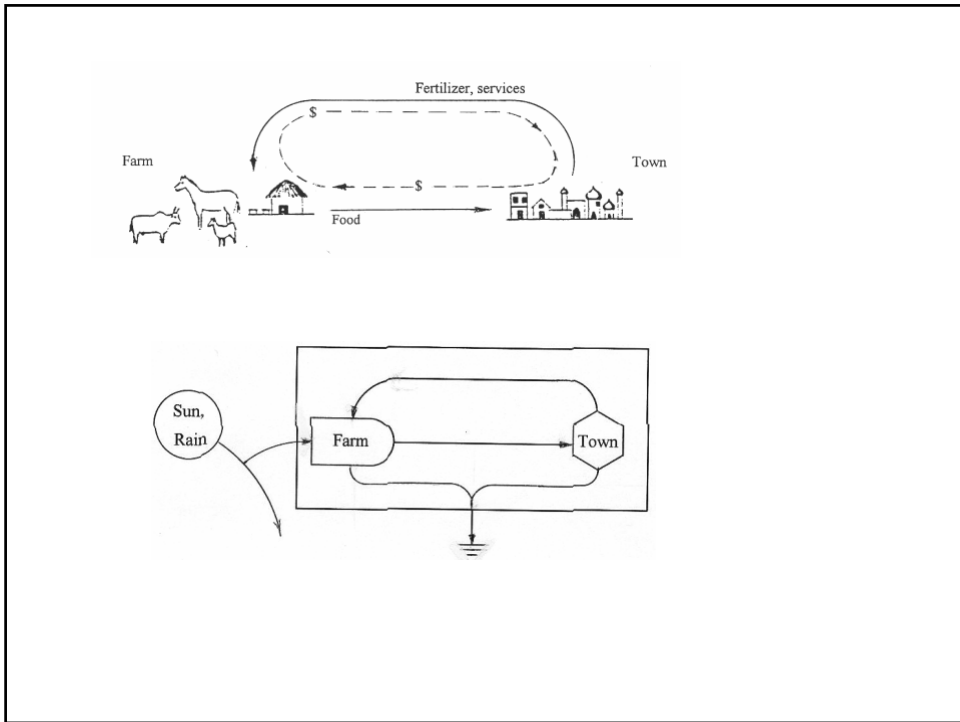


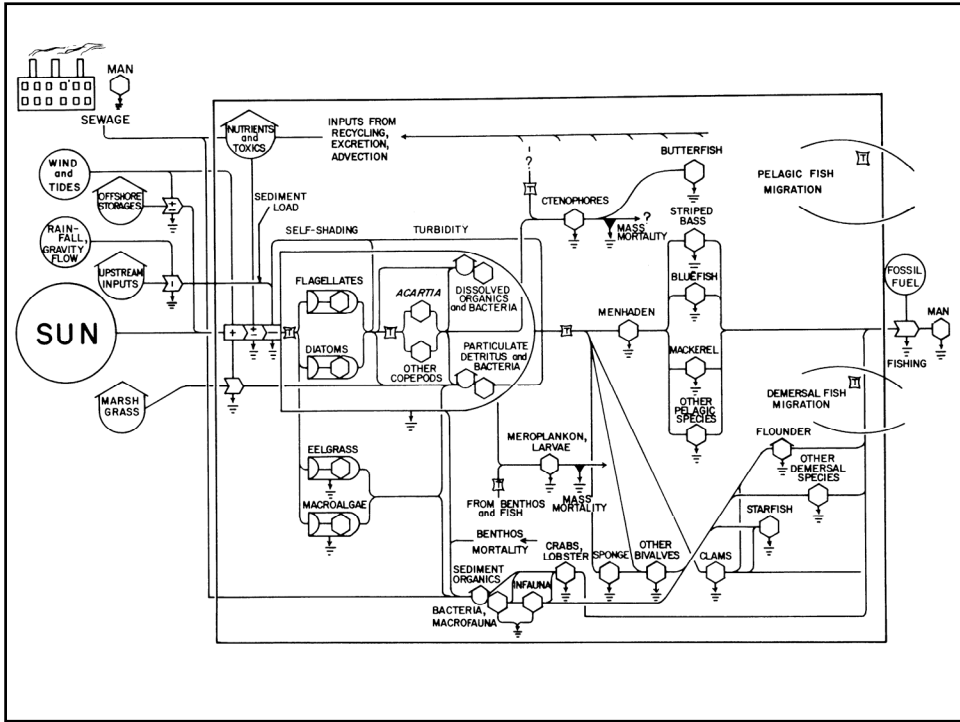
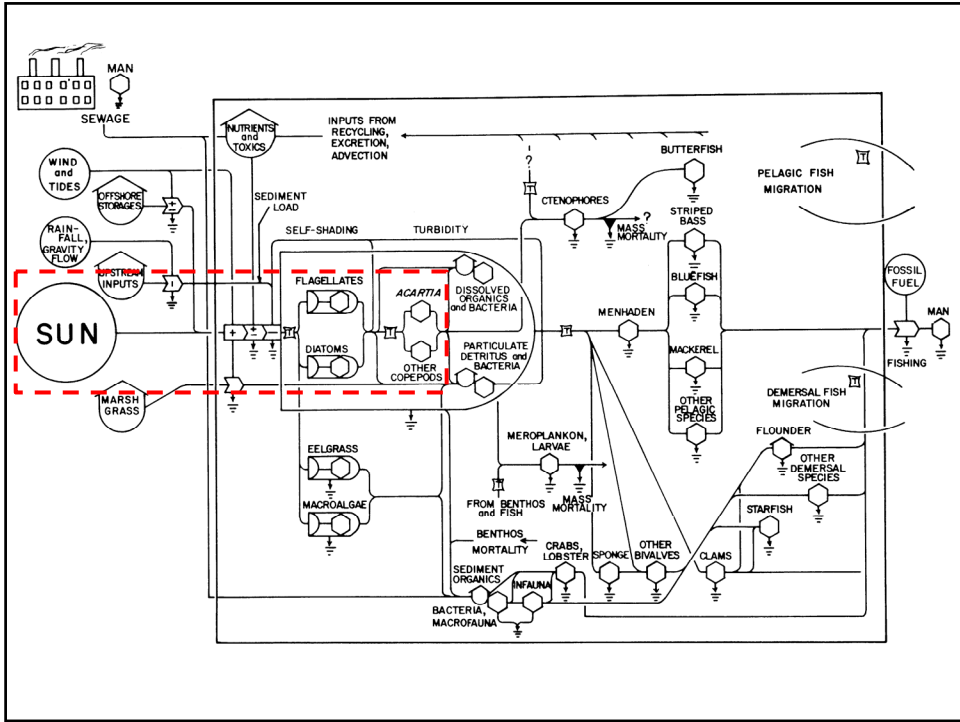
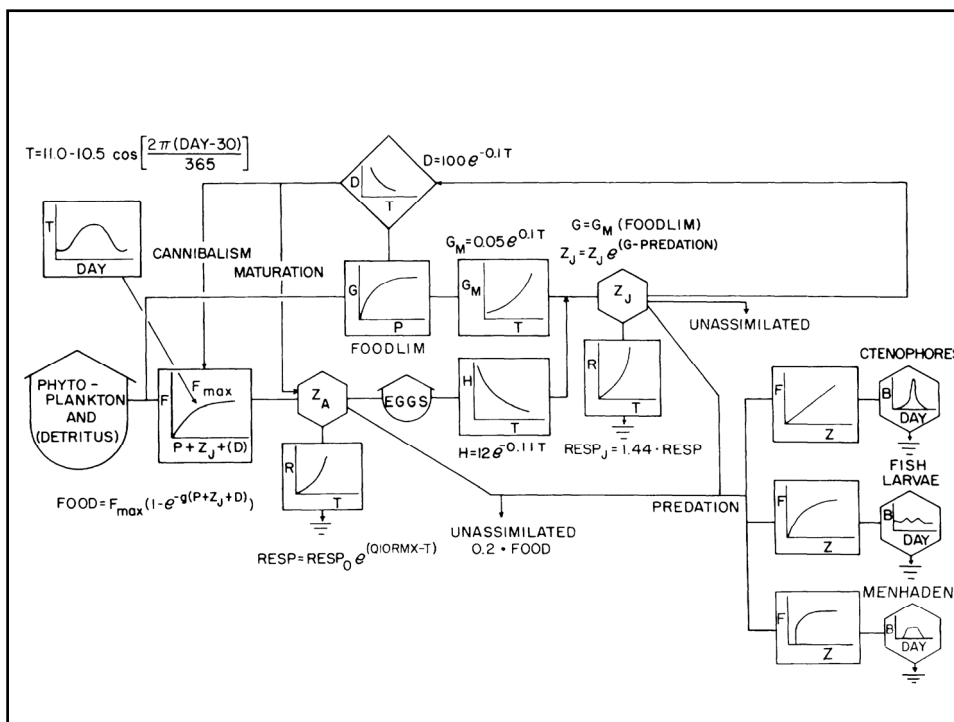
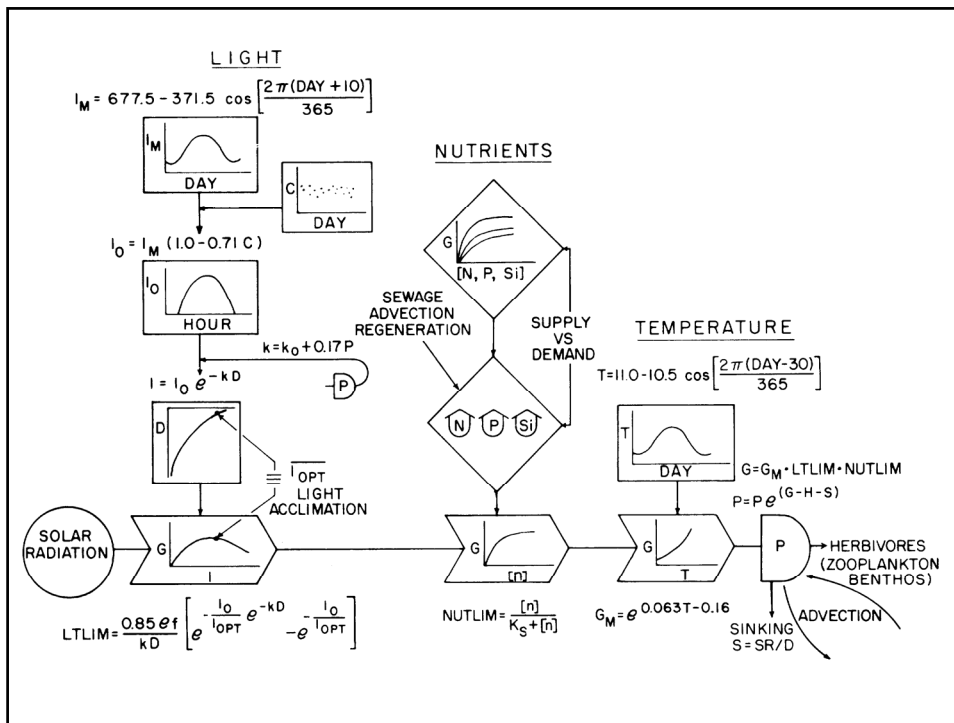


Figure 8 Model of the farm "half" of Fig. 7





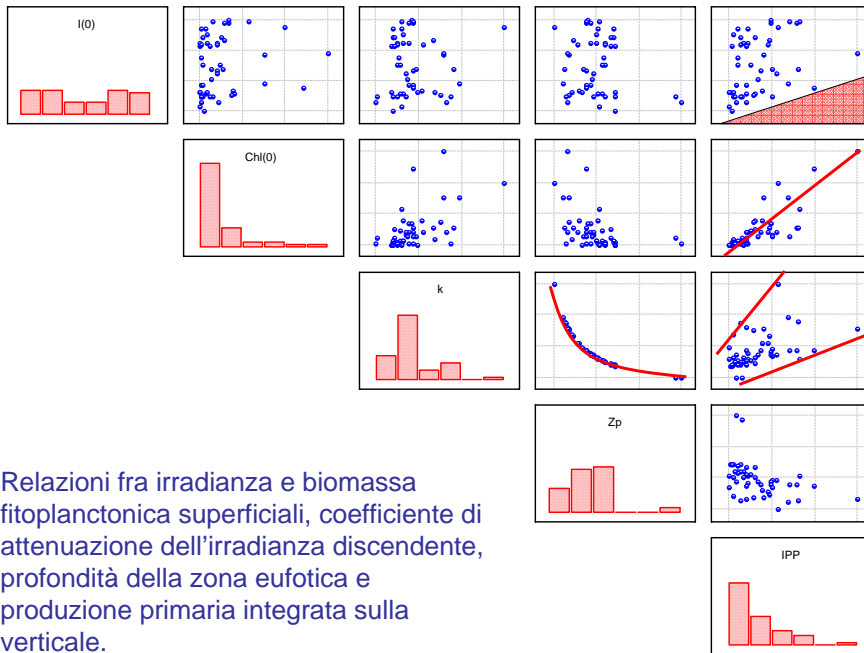



Modelli empirici

Stima della produzione primaria

- La produzione primaria dipende da:
 - Biomassa fitoplanctonica
 - Irradianza
 - Temperatura
 - Efficienza fotosintetica del fitoplancton
- La biomassa fitoplanctonica dipende da:
 - Produttività primaria
 - Disponibilità di nutrienti
 - Scambi advettivi

data	$I_0(\text{PAR})$ $Em^{-2}d^{-1}$	$CHL_m(0-2)$ $mg\ m^{-3}$	k m^{-1}	z_p m	$P_T(0-60)$ $mg\ C\ m^{-2}\ d^{-1}$
02/09/84	11.831	3.04	0.113	40.8	678
03/01/84	15.110	0.25	0.087	53.0	80
03/15/84	30.966	0.93	0.100	46.1	168
03/29/84	13.783	7.33	0.112	41.2	426
04/12/84	37.119	13.52	0.127	36.3	541
04/26/84	44.005	3.93	0.127	36.3	325
05/09/84	45.180	5.27	0.128	36.0	620
05/24/84	55.343	6.26	0.109	42.3	657
06/06/84	12.762	6.83	0.123	37.5	410
06/28/84	57.094	6.25	0.126	36.6	646
07/10/84	55.333	5.20	0.119	38.7	1027
07/24/84	52.449	0.51	0.111	41.5	313
08/08/84	47.360	0.92	0.089	51.8	210
08/21/84	43.527	0.32	0.094	49.0	247
09/07/84	42.333	0.25	0.087	53.0	85
09/18/84	15.649	7.20	0.158	29.2	536
...





Vertically Generalized Production Model (VGPM)

(Behrenfeld & Falkowski, 1997)

$$\Sigma PP := 0.66125 \cdot P_{b_opt} \cdot \frac{I_0}{I_0 + 4.1} \cdot Chl \cdot Z_{eu} \cdot DI$$

Where:

$$Chl_{tot}(Chl) := \text{if}(Chl < 1.0, 38.0 \cdot Chl^{0.42}, Chl)$$

$$Z_{eu}(Chl) := \text{if}\left[568.2 \cdot \left(\frac{Chl_{tot}}{100}\right)^{-0.746}, 100\right]$$

$$P_{b_opt}(SST) := \text{if}(SST < -1, 0, \text{if}(SST < 10, 0.01, \text{if}(SST < 13.83, 0.1, 13.21)))$$

VGPM can be redefined as:


$$\Sigma PP(Chl, I_0, SST, DI) := 0.66125 \cdot P_{b_opt}(SST) \cdot \frac{I_0}{I_0 + 4.1} \cdot Chl \cdot Z_{eu}(Chl) \cdot DI$$

E.g.: $\Sigma PP(.601, 0.1, 13.83, 13.21) = 29.095$

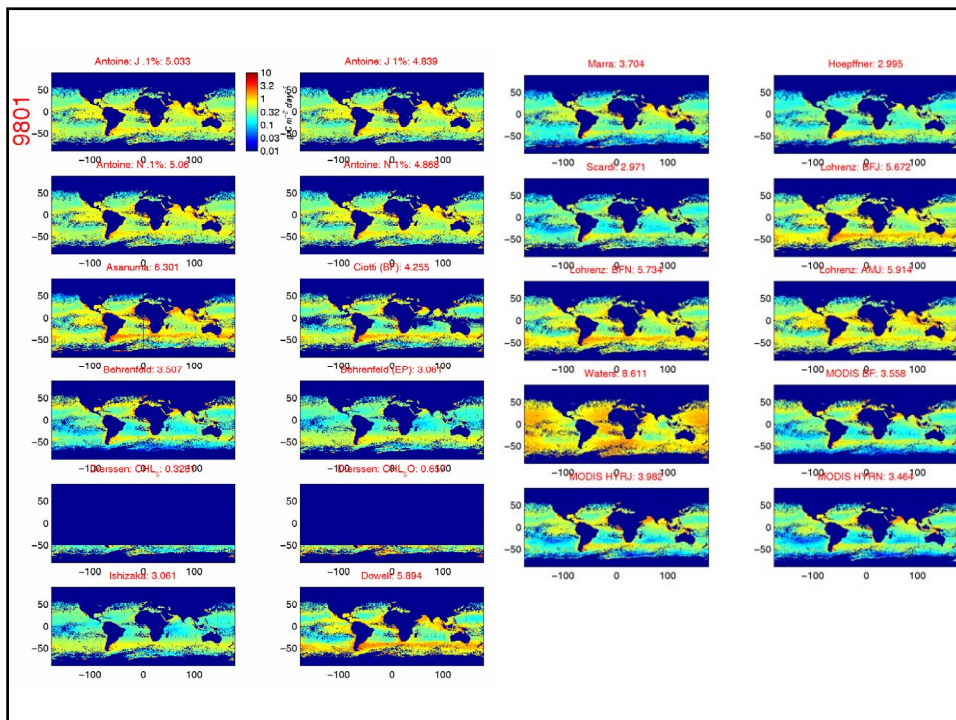

$PP = f(B_0, Z_p, \text{fotoperiodo}, P_B^{opt})$
 $Z_p = f(B_0)$
 $P_B^{opt} = f(SST)$

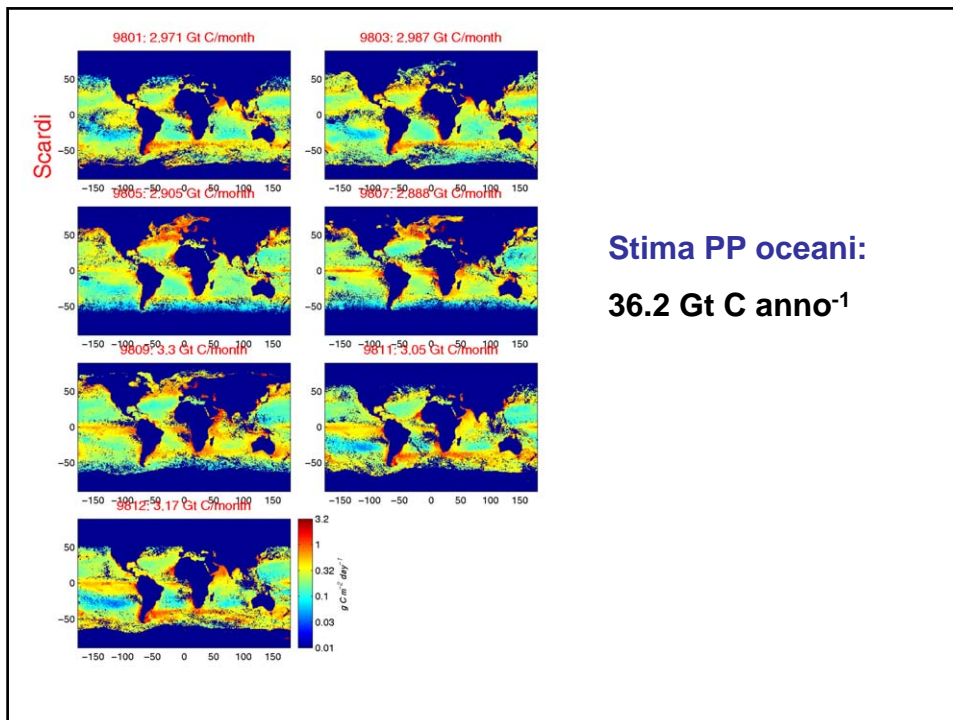
More info about VGPM at <http://warrior.rutgers.edu>

PP media in giugno



$\text{g C m}^{-2} \text{giorno}^{-1}$





Modelli empirici di nuova generazione: reti neurali

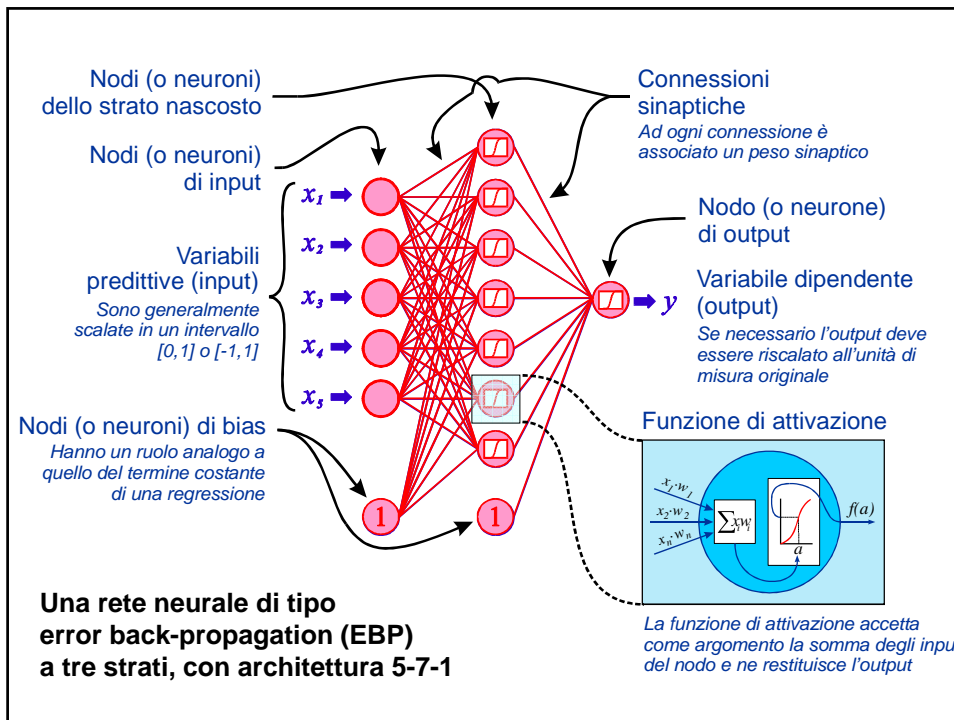
“...a neural network is a system composed of many simple processing elements operating in parallel whose function is determined by network structure, connection strengths, and the processing performed at computing elements or nodes.”

“...una rete neurale è un sistema composto da molti elementi di processo semplici che operano in parallelo, la cui funzione è determinata dalla struttura della rete, dall'intensità delle connessioni e dai processi attuati negli elementi di calcolo o nodi.”

*(DARPA Neural Network Study, 1988,
AFCEA International Press, p. 60)*

**COME FUNZIONANO
LE RETI NEURALI?**

SOLO UN PIZZICO DI TEORIA...



L' algoritmo EBP

L'algoritmo EBP (Rumelhart et al., 1986) è di gran lunga il più diffuso fra gli algoritmi di training per le reti neurali e può essere schematizzato come segue:

1. le connessioni sinaptiche sono inizializzate in maniera casuale

$$w_{jk} = rnd[0,1] \quad \begin{cases} j = 1, \dots, n_{i+1} \\ k = 1, \dots, n_h \end{cases}$$

$$z_{kl} = rnd[0,1] \quad \begin{cases} k = 1, \dots, n_{h+1} \\ l = 1, \dots, n_o \end{cases}$$

2. un training pattern è immesso nella rete neurale

$$h_k = \sum_{j=1}^{n_{i+1}} i_j w_{jk} \quad (k = 1, \dots, n_h) \quad h_k = f(h_k) \quad h_{n_h+1} = 1$$

$$h_k = \sum_{j=1}^{n_{i+1}} i_j w_{jk} \quad (k = 1, \dots, n_h) \quad h_k = f(h_k) \quad h_{n_h+1} = 1$$

3. tutti i pesi sinaptici vengono quindi modificati in funzione dello scarto rilevato tra outputs e valori noti (error-backpropagation)

$$z_{kl} = z_{kl} + \eta \delta_l^o h_k \quad (k = 1, \dots, n_{h+1}; l = 1, \dots, n_o)$$

$$\delta_l^o = (y_l - o_l) \cdot f'(o_l) = (y_l - o_l) \cdot o_l (1 - o_l)$$

$$w_{jk} = w_{jk} + \eta \delta_k^h i_j \quad (k = 1, \dots, n_{h+1}; j = 1, \dots, n_{i+1})$$

$$\delta_k^h = f'(h_k) \cdot \sum_{l=1}^{n_o} \delta_l^o z_{kl} = h_k (1 - h_k) \cdot \sum_{l=1}^{n_o} \delta_l^o z_{kl}$$

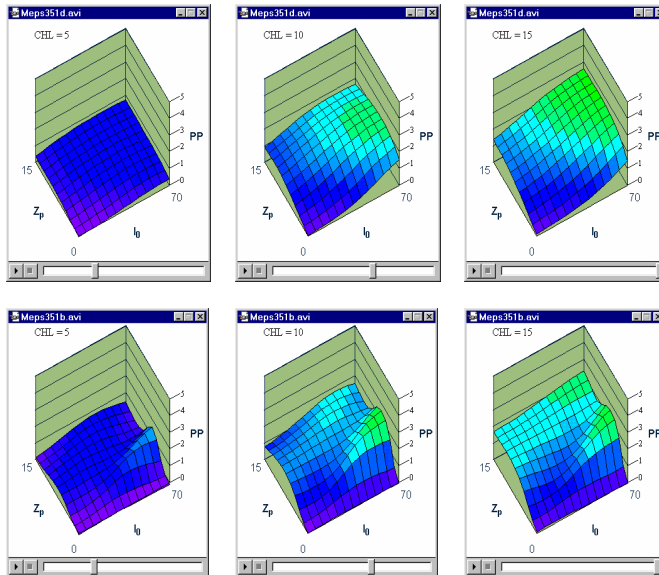
4. l'output della rete è confrontato con i valori noti del set di validazione

$$E = \frac{1}{n_o} \sum_{l=1}^{n_o} (y_l - o_l)^2$$


5. se le condizioni di convergenza sono raggiunte, si termina il training, altrimenti si torna al punto 2

Demo


$$PP = f(l_0, Z_p, CHL)$$



generalizzazione



overfitting



PER EVITARE L'OVERFITTING:

- *early stopping*
- *jittering* (aggiunta di rumore agli inputs)
- *weight decay*
- *training patterns* in ordine casuale
- etc.

INOLTRE, PER UNA BUONA GENERALIZZAZIONE:

- gli inputs devono contenere abbastanza informazione predittiva in rapporto agli outputs desiderati (targets)
- la relazione da modellizzare deve essere preferibilmente regolare (cioè piccola variazione in input --> piccola variazione in output)
- il training set deve essere abbastanza grande e comunque deve essere un sottoinsieme rappresentativo del sistema reale

skip


**A PHYTOPLANKTON PRIMARY
PRODUCTION MODEL FOR
CHESAPEAKE BAY**

Michele Scardi¹ & Lawrence W. Harding, Jr.²

1. Dept. of Biology, Univ. of Roma "Tor Vergata", Roma, Italy

2. Horn Point Lab., University of Maryland, USA

Chesapeake Bay



Phytoplankton primary production in Chesapeake Bay





Predictive variables

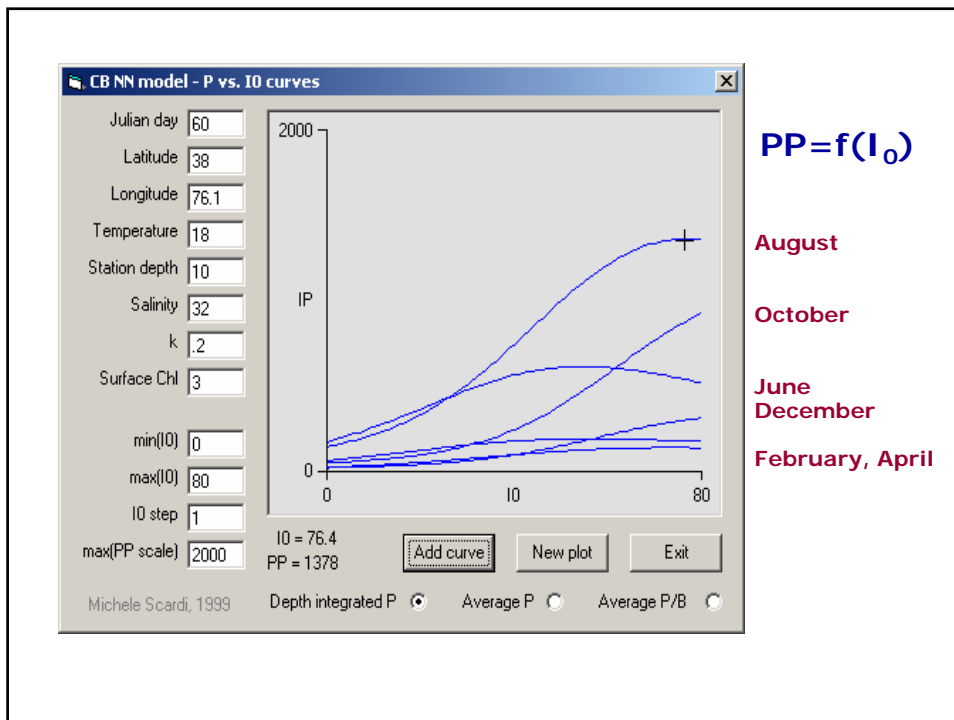

- $\frac{1}{2} \left[\cos \left(\frac{JulianDay}{2 \cdot 365 \cdot \pi} \right) + 1 \right]$
- $\frac{1}{2} \left[\sin \left(\frac{JulianDay}{2 \cdot 365 \cdot \pi} \right) + 1 \right]$
- latitude
- longitude
- depth
- water temperature
- salinity
- log chlorophyll
- log chlorophyll (Z_p)
- I_0 (PAR)
- k
- Z_p

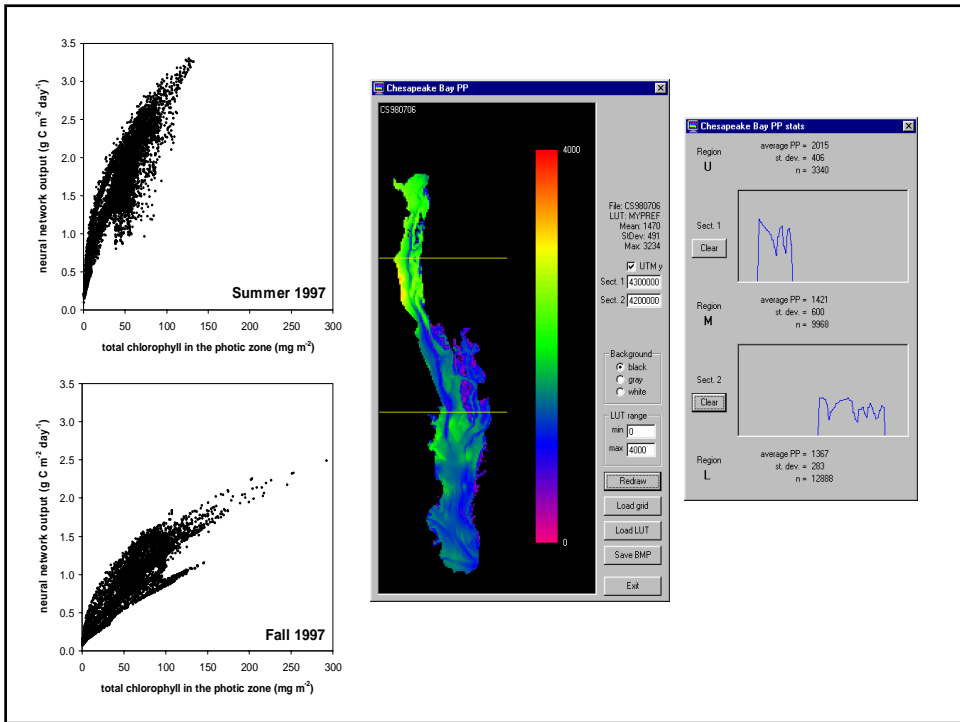
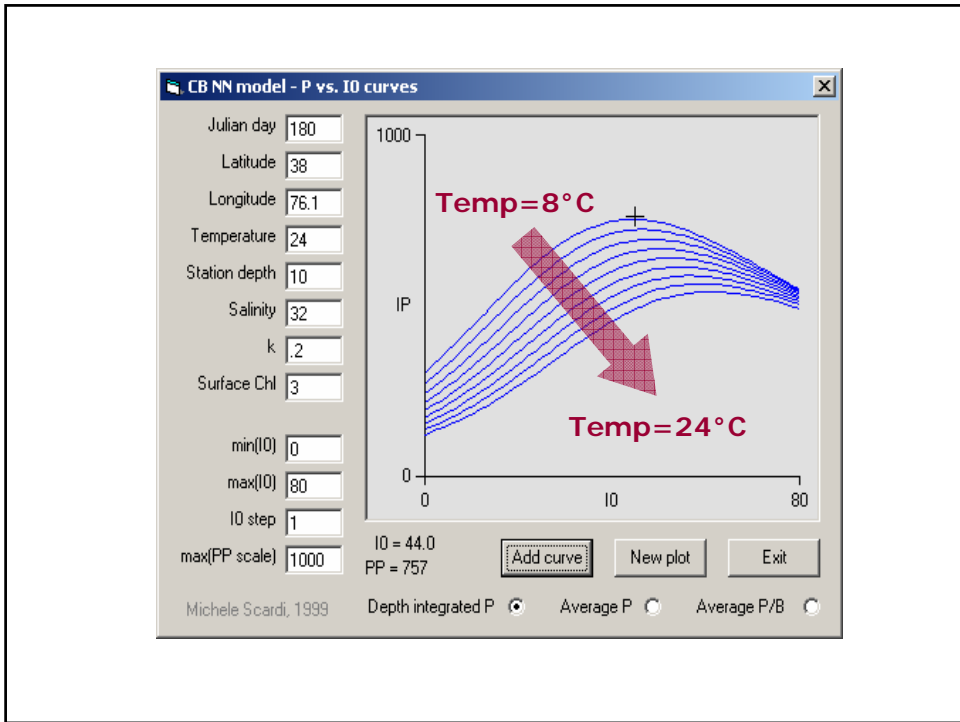
NN structure: 12 - 5 - 1

Output variable: primary production ($\text{mg C m}^{-2} \text{ day}^{-1}$)

- training and validation sets (1982-96)
- testing set (1997)







PREVISIONE DELLA STRUTTURA DELLA FAUNA ITTICA MEDIANTE RETI NEURALI ARTIFICIALI

Michele Scardi¹, Stefano Cataudella¹, Paola Di Dato¹,
Giuseppe Maio², Enrico Marconato², Stefano Salviati²,
Lorenzo Tancioni¹, Paolo Turin³ e Marco Zanetti³

1. Dip. di Biologia, Univ. di Roma "Tor Vergata", Roma

2. Aquaprogram s.r.l., Vicenza

3. Bioprogramm s.c.r.l., Padova

Problema applicativo #1:

- 1. Previsione della composizione della fauna ittica sulla base di **predittori** ambientali**
- 2. Comparazione della composizione **attesa** con quella **osservata****
- 3. Formulazione di un giudizio di **qualità ambientale** (es. *sensu* Direttiva 2000/60/CE)**

Problema applicativo #2:

- 1. Analisi di sensibilità** del modello previsionale
- 2. Identificazione dei fattori ambientali** che determinano le maggiori variazioni nella risposta del modello
- 3. Definizione di possibili strategie** per la **gestione** dell'ambiente

Previsione della composizione di una comunità

- Caso 1:** numero limitato di specie
- Caso 2:** molte specie, ma un singolo cenocline (in teoria, tutte le risposte sono unimodali)
- Case 3:** molte specie e più cenoclini (interazioni di ordine superiore fra variabili ambientali)
- Case 4:** elevatissimo numero di specie, cenospazio estremamente complesso con discontinuità

Caso 1 o 2: poche specie o singolo cenocline

- Buoni risultati si possono ottenere sia con metodi convenzionali (es. regressione logistica), sia con le **reti neurali**.
- Le **relazioni implicite** (non note) fra specie **riducono** significativamente la **dimensionalità reale** del problema.
- Solo le **reti neurali** possono trarre vantaggio da ciò.

Specie presenti nel data set:

32

Combinazioni possibili:

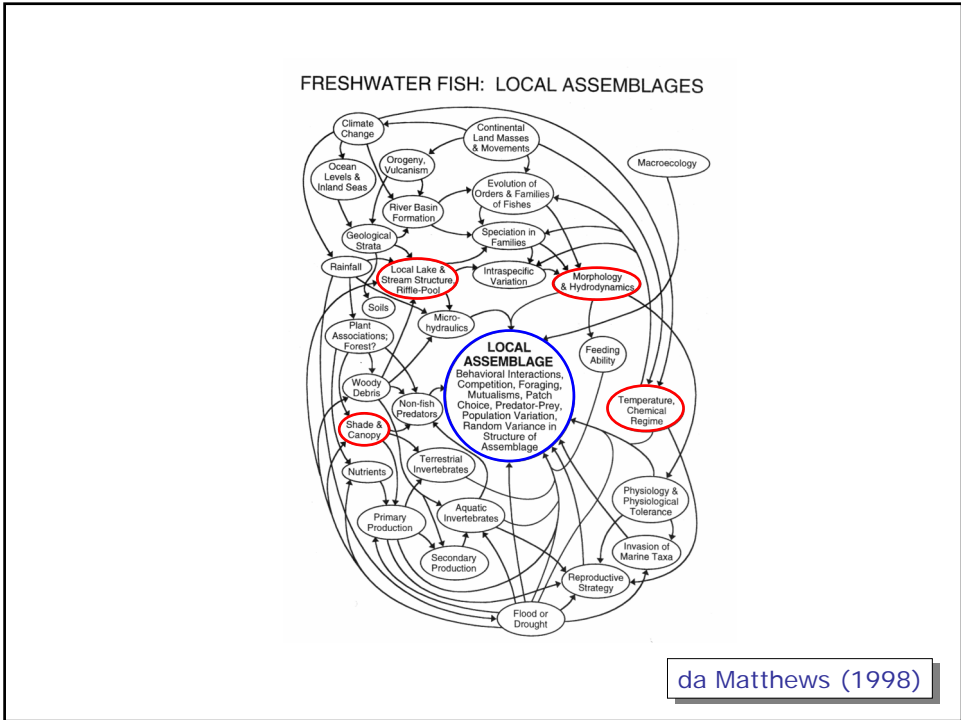

$2^{32} = 4294967296$

Combinazioni osservate:

131 su 264 casi

Le specie non sono indipendenti le une dalle altre (meno male, se no, poveri ecologi!)

Una rete neurale può "catturare" l'informazione relativa alle relazioni interspecifiche (es. competizione), migliorando la sua capacità predittiva



Variabili predittive (inputs NN)

- 1 altitudine (m)
- 2 profondità media (m)
- 3 correnti (superficie, %)
- 4 pozze (superficie, %)
- 5 raschi (superficie, %)
- 6 larghezza media (m)
- 7 massi (superficie, %)
- 8 sassi e ciottoli (superficie, %)
- 9 ghiaia (superficie, %)
- 10 sabbia (superficie, %)
- 11 peliti (superficie, %)
- 12 velocità flusso (punteggio, 0-5)
- 13 copertura vegetale (superficie, %)
- 14 ombreggiatura (%)
- 15 disturbo antropico (punteggio, 0-4)
- 16 pH
- 17 conducibilità ($\mu\text{S}/\text{cm}$)
- 18 gradiente (%)
- 19 bacino versante (km^2)
- 20 distanza dalla sorgente (km)

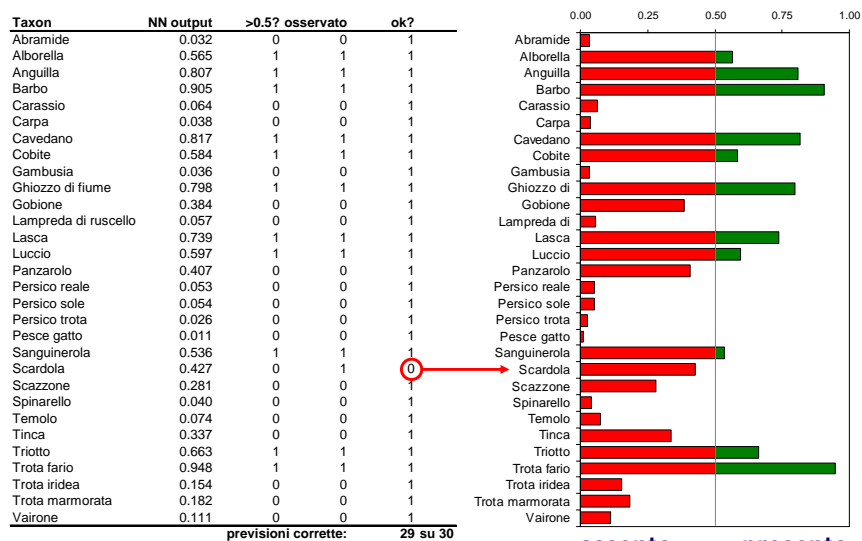
Taxa considerati

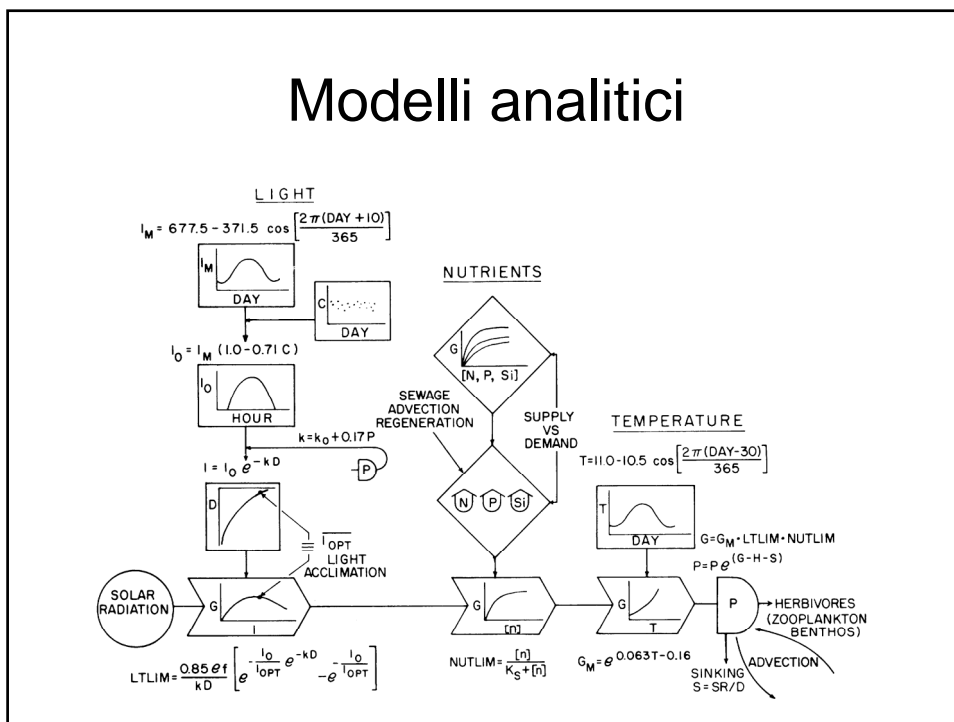
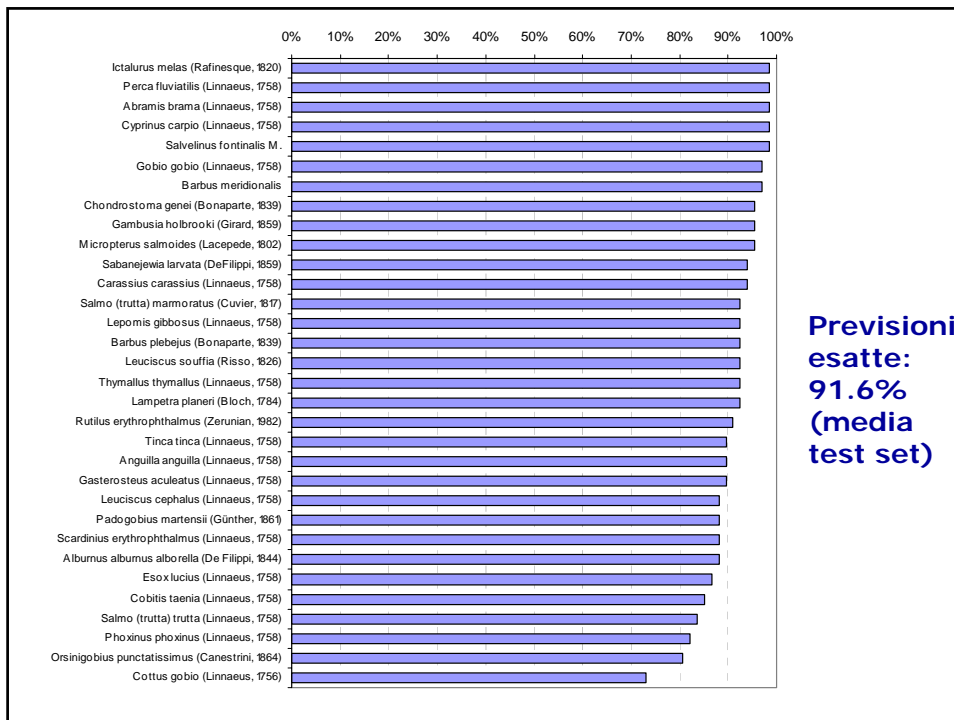
<i>Abramis brama</i>	<i>Leuciscus cephalus</i>
<i>Alburnus alburnus alborella</i>	<i>Leuciscus souffia</i>
<i>Anguilla anguilla</i>	<i>Micropterus salmoides</i>
<i>Barbus meridionalis</i>	<i>Orsinogobius punctatissimus</i>
<i>Barbus plebejus</i>	<i>Padogobius martensii</i>
<i>Carassius carassius</i>	<i>Perca fluviatilis</i>
<i>Chondrostoma genei</i>	<i>Phoxinus phoxinus</i>
<i>Cobitis taenia</i>	<i>Rutilus erythrophthalmus</i>
<i>Cottus gobio</i>	<i>Sabanejewia larvata</i>
<i>Cyprinus carpio</i>	<i>Salmo (trutta) marmoratus</i>
<i>Esox lucius</i>	<i>Salmo (trutta) trutta</i>
<i>Gambusia holbrooki</i>	<i>Salvelinus fontinalis</i>
<i>Gasterosteus aculeatus</i>	<i>Scardinius erythrophthalmus</i>
<i>Gobio gobio</i>	<i>Thymallus thymallus</i>
<i>Ictalurus melas</i>	<i>Tinca tinca</i>
<i>Lampetra planeri</i>	<i>Salmo (trutta) hybr. trutta/marmoratus</i>
<i>Lepomis gibbosus</i>	<i>Oncorhynchus mykiss</i>

Struttura del modello: 20-17-32

- 264 patterns (campioni)
 - training, n=131
 - validazione, n=66
 - test, n=67
- 20 variabili ambientali predittive
- 32 specie (dati binari, presenza/assenza)
- training della rete neurale: algoritmo di error back-propagation con early stopping basato sull'errore del set di validazione

Un esempio di output





$$\frac{dP}{dt} = f(I, T, N)P - g(P, T)Z - c_{mp}P \pm \text{scambi}$$

$$\frac{dZ}{dt} = g(P, OM, T)Z - h(T)Z - c_{na}g(P, T)Z - c_{mz}Z \pm \text{scambi}$$

$$\frac{dOM}{dt} = c_{np}P + c_{na}g(P, T)Z - k(T)OM - c_sOM \pm \text{scambi}$$



$$\frac{dN}{dt} = 12 \dots P, T)Z + k(T)OM - f(I, T, N)P \pm \text{scambi}$$

$$g(P, OM, T) = g_{\max} \cdot [g_1(P) + g_2(OM)] \cdot g_3(T)$$

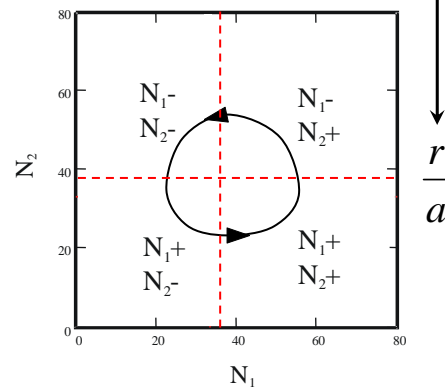
$$g_3(T) = \frac{T}{T_{opt}} e^{1 - \frac{T}{T_{opt}}}$$

Parametri del modello (assunti come costanti)

densità iniziale fitoplancton (Chl mg m ⁻³)	10
densità iniziale zooplancton (DW mg m ⁻³)	0.2
concentrazione iniziale SOM (mg C m ⁻³)	20
conc. iniziale azoto inorg. (mM N dm ⁻³)	1
numero di giorni simulati dall'1 gennaio	1460
torbidità relativa (componente inorganica)	2
temperatura massima acqua (°C)	26
temperatura minima acqua (°C)	10
tasso di crescita massimo del fitoplancton	0.59
pendenza della curva di crescita come f(T)	0.075
costante di semisaturazione per l'azoto	1.1
tasso di mortalità naturale fitoplancton	0.15
cost. conversione mg C dm ⁻³ -> mM Nxy dm ⁻³	0.0126
tasso di crescita max zooplancton erbivoro	1.2
costante di semisaturazione per il grazing	25
coeff. preferenza grazing su fitoplancton	0.66
coeff. preferenza grazing su part. org.	0.33
tasso di respirazione a 0 °C	0.06
pendenza curva respirazione [f(T)]	0.085
razione di fitoplancton non assimilata	0.33
tasso di mortalità dello zooplancton	0.21
tasso di decomposizione della SOM a 0 °C	0.05
pendenza funzione decomposizione [f(T)]	0.06
tasso di sedimentazione della SOM	0.33



$$\begin{cases} \frac{dN_1}{dt} = rN_1 - aN_1N_2 = 0 \text{ per } N_2 = \frac{r}{a} \\ \frac{dN_2}{dt} = baN_1N_2 - mN_2 = 0 \text{ per } N_1 = \frac{m}{ba} \end{cases}$$



```

Sub MODELLO(f(),Y(),r1,p1,r2,m2)
'prede
f(1) = r1 * Y(1) - p1 * Y(1) * Y(2)
'predatori
f(2) = r2 * p1 * Y(1) * Y(2) - m2 * Y(2)
End Sub

Static Sub PREDCORR(x0, x9, k1, n%, k5, e, z%, fl%)
ReDim w(1 To 9) As Single
ReDim h2(n%, 22) As Single
On Error GoTo ErrorHandler
'verifica le possibili condizioni di errore alla
chiamata
If x0 >= x9 Then fl = 1: Exit Sub
If (n% <= 0) Or (n% <> Int(n%)) Then fl = 2: Exit Sub
If (k5 <= 0) Or (k5 <> Int(k5)) Then fl = 3: Exit Sub
If (k1 <= 0) Or (k1 <> Int(k1)) Then fl = 4: Exit Sub
If e < 0.000000001 Then fl = 5: Exit Sub
If (z - 1) * (z - 2) <> 0 Then fl = 6: Exit Sub
'definizione delle costanti
w(1) = 0.2071067811865
w(2) = 0.2928932188135
w(3) = 0.1
'inizializzazione
For i% = 1 to n%
  For j% = x0 to x9
...

```

skip

Skip

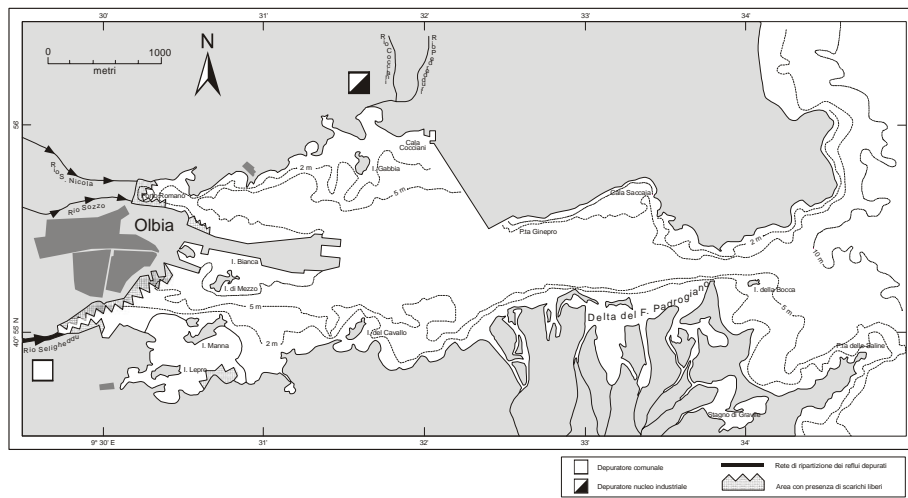
$$\frac{dN_1}{dt} = rN_1 - aN_1N_2$$

$$\frac{dN_2}{dt} = baN_1N_2 - mN_2$$

	A	B	C	D	E	F
1	P(0)	100	t	P(t)	Q(t)	
2	Q(0)	20		0	100	20
3	a	0.05		0.01	101	20.05
4	r	2		0.02	102.007	20.1016
5	b	0.15		0.03	103.022	20.1549
6	m	0.5		0.04	104.045	20.2099
7				0.05	105.074	20.2665
8	passo	0.01		0.06	106.111	20.3249
9				0.07	107.155	20.385
10				0.08	108.206	20.4469
11				0.09	109.264	20.5106
12				0.1	110.328	20.5762
13				0.11	111.4	20.6435
14				0.12	112.478	20.7128
15				0.13	113.563	20.784

http://www.mare-net/mscardi/work/ecologia/mod_preda_predatore.xls

Simulazione di scenari di gestione ambientale nel Golfo di Olbia



$$\frac{dP}{dt} = f(T, I, N)P - g(P, T)Z - c_{mp}P \pm \text{scambio}$$

$$\frac{dZ}{dt} = (1 - c_{na}) \dots - h(T)Z - c_{mz}Z \pm \text{scambio}$$

$$\frac{dOM}{dt} = c_{mp}P + c \dots - k(T)OM - c_{om}OM \pm \text{scambio} + \text{reflui} + \text{escrezione}$$

$$\frac{dN}{dt} = c_{CN} \cdot (n(I)Z + k(I)OM - j(I, N)P) + j(z, I) \pm \text{scambio} + \text{reflui} + \text{escrezione}$$

$f(T, I, N) = \mu(T) \cdot f_1(I) \cdot f_2(N)$

$$\mu(T) = \mu_{\max} \frac{e^{k_I T}}{e^{k_I T_{\max}}}$$

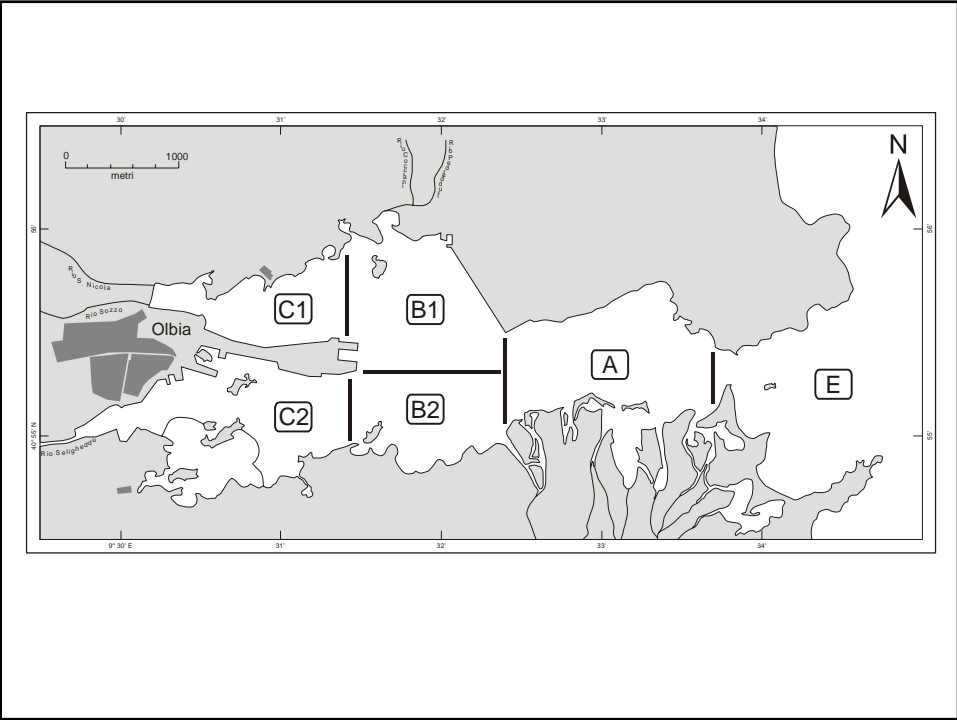
$$f_1(I) = \frac{\bar{I}}{I_{opt}} e^{1 - \frac{\bar{I}}{I_{opt}}}$$

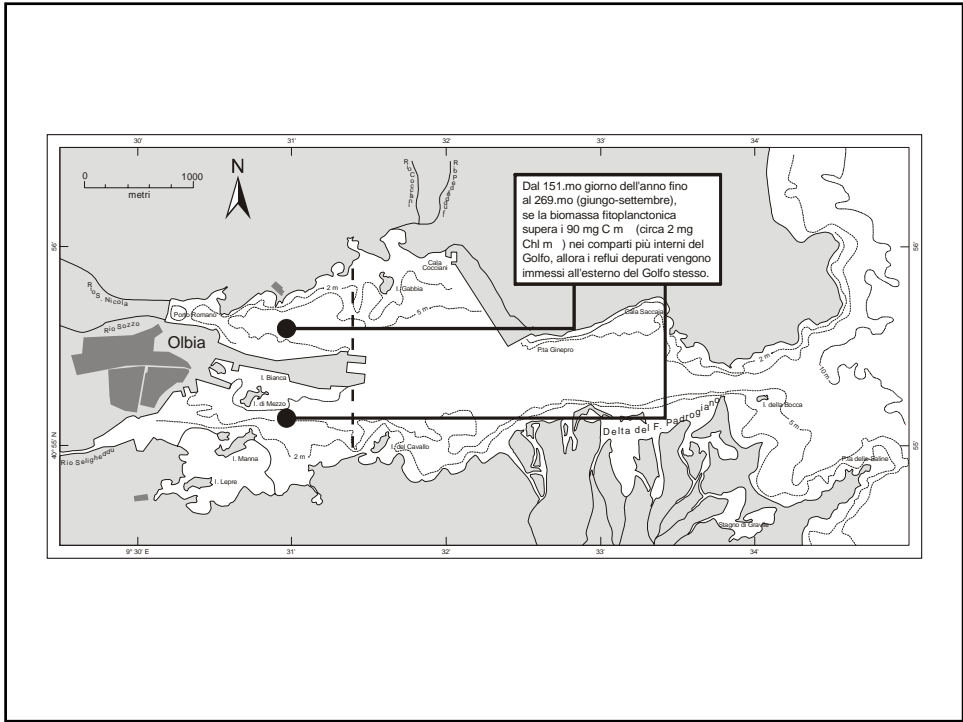
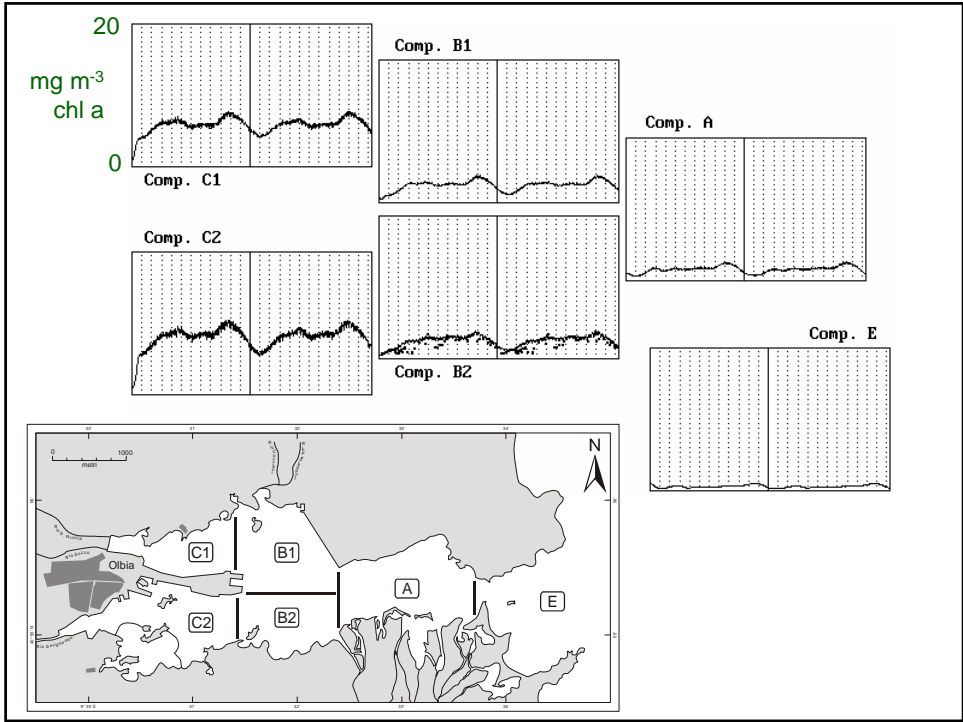
$$f_2(N) = \frac{N}{k_N + N}$$

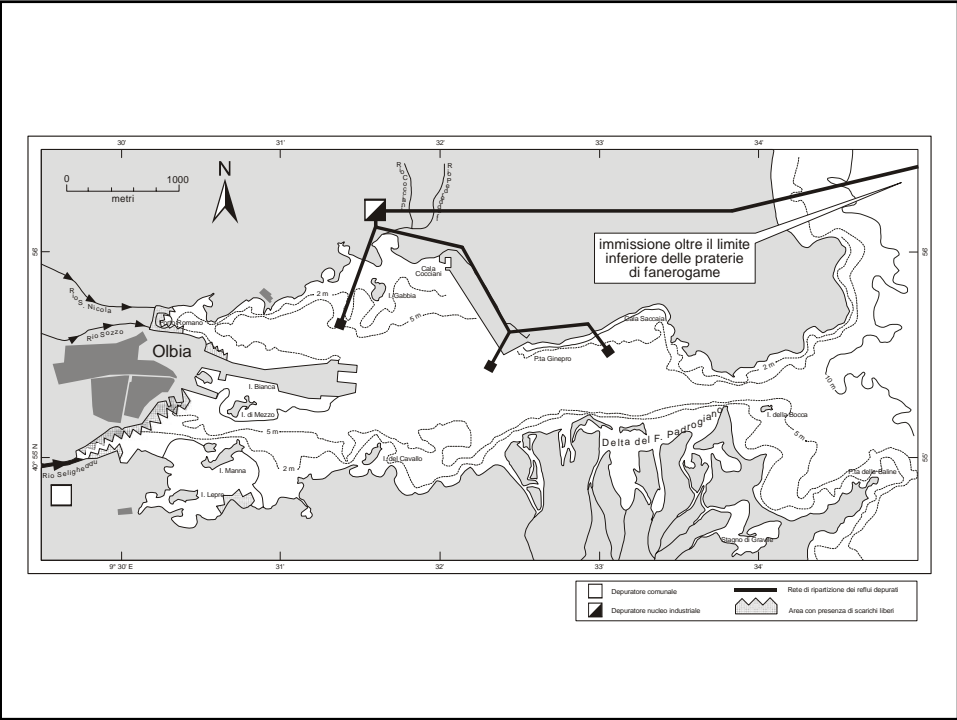
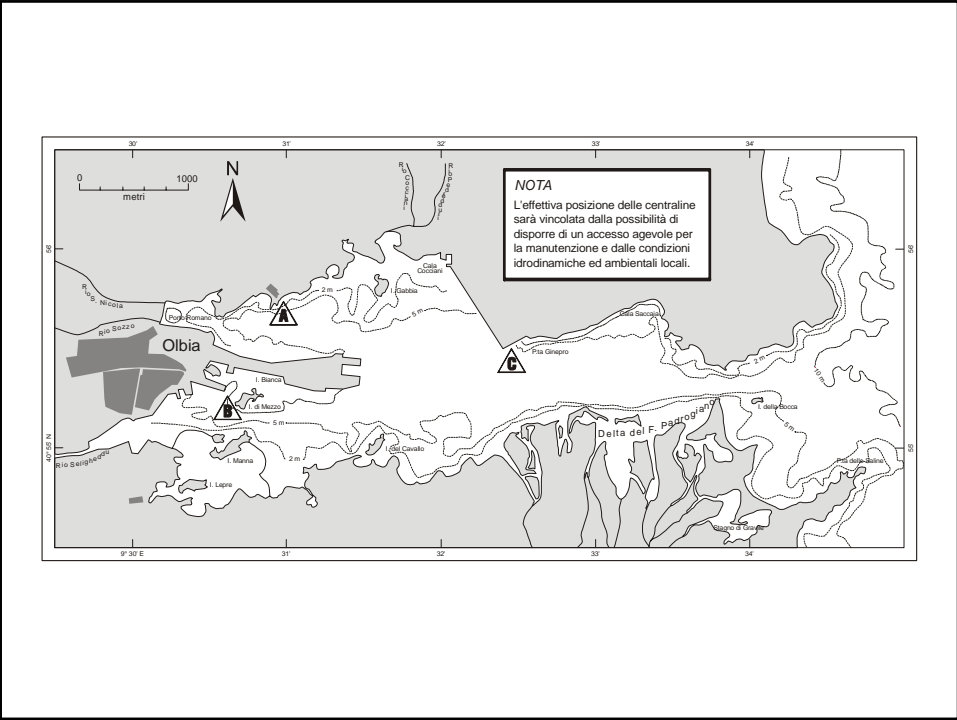
$$\bar{I} = \frac{1}{z} \int_0^z I_0 e^{-cz} dz$$


$$I_{opt} = 0.7 \cdot \bar{I}_{t-1} + 0.2 \cdot \bar{I}_{t-2} + 0.1 \cdot \bar{I}_{t-3}$$

$$c = 0.35 + 0.05 \cdot P_{chl}$$









USO COMBINATO DI DIVERSE TIPOLOGIE DI MODELLI

**Analisi della produttività dello
Stagno del Calich (Sardegna)**

