

ニューラルネットワークを用いた稲の出穂予測法の 検討

横山, 剛宗
九州大学農学部生物資源環境学科生産環境科学専攻生産環境情報学研究室

<https://hdl.handle.net/2324/1498265>

出版情報 : Kyushu University, 2007, 学士, 学士
バージョン :
権利関係 :

卒業論文

ニューラルネットワークを用いた稲の出穂予測法の検討

九州大学農学部生物資源環境学科生産環境科学専攻

生産環境情報学研究室

横山剛宗

2008 年 3 月

目次

第1章 序論	1
第2章 稲の生理	3
稲の発育史	
第3章 出穂予測モデル	7
3-1 既存の発育予測モデル	
(1) 気温による予測モデル	
(2) 気温と日長による予測モデル	
3-2 堀江らのモデル(1986)による出穂予測	
(1) 最小二乗法	
(2) 勾配法(最急降下法)によるモデルパラメータの決定	
(3) シンプレックス法(単体法)によるモデルパラメータの決定	
(4) 遺伝的アルゴリズムによるモデルパラメータの決定	
第4章 ニューラルネットワーク(NN)の理論	21
4-1 ニューラルネットワーク概説	
4-2 NNを構築する素子の構造	
(1) 神経細胞(ニューロン)の構造	
(2) ニューラルの入出力関係の数式モデル化	
(3) NNの構造	
(4) NNの学習	
第5章 ニューラルネットワークを用いた出穂予測モデルの構築	43
第6章 出穂期の予測モデルによる移植日決定の結果 学習外データに対する精度に対する考察	45
第7章 結論	49

第 1 章 序論

近年，稲の登熟期における気温の高温化が進んでる．登熟期における高温は，背白米や基白米，乳白米の多発といった，玄米の外見品質の低下や米の食味の低下などを招くことが確認されており，高温登熟による米の品質低下は問題となっている．粒の充実や外見品質から考えられる適温は 20~25℃前後とされている．（注：日作紀講演会要旨・資料集 第 25 巻）また，食味における登熟期の最適温度は 25~26℃付近にあるとされている．（佐藤ら：2005）

このように，近年の登熟期における高温化とそれによる米の品質低下を防ぐため，登熟期の温度を最適化することは，きわめて重要な課題であり，移植期を調節することで，登熟期の温度を最適化する研究は大きな意義を持つ．

登熟期の気温を最適化するには，その年の予想気温を基に，稲の登熟環境を評価する必要がある．そのためには移植期と出穂期の関係を予測し，出穂期の予想気温が最適気温と一致するように，移植日を調整，決定すればよい．よって，移植期の決定には移植日からの出穂予測モデルが必要となる．

したがって，本研究では，移植日からの出穂予測モデルを作成し，そのモデルを用いて，移植日を決定することで登熟期の気温の最適化し，またそれに伴う米の品質保持，向上を導く農業シナリオを解明を目指すものである．

従来，出穂予測に活用し得る発育ステージの予測モデルとして，積算温度法，重回帰式による方法，発育速度（DVR）の概念に基づく方法等，多数の予測モデルが提案されている．上述の方法の中で，積算温度法は，適用できる範囲が狭く，予測精度が低いことが報告されている（田村，1989）．また，重回帰による方法も温度のみを説明変数として用いているために，早生などの感光性の低い品種と中生・晩生などの感光

性の高い品種の違いが評価しづらく，高感光性の品種へは適用性が低いと考えられる．一方，DVR の概念に基づく堀江ら（1990）の方法は，稲の発育ステージを感光相と非感光相に分割し，それぞれのステージにおける気温，日長と DVR の関係をモデル化したもので，既往のモデルの中では予測精度が高い（日本晴で標準誤差 3.6 日）．そこで本研究では，当初，この方法から，出穂予想モデルを作り，登熟の最適化を目指した．しかしながら，このモデルは，気温，日長と DVR の関係に比較的単純な関数形を仮定していることからパラメータ推定の際の評価関数が多峰性を有することになり，また，パラメータ数が多いため，とあるパラメータによる誤差が別のパラメータによる誤差によって打ち消されてしまうなどの欠点を持つ．そのため，本来モデルが意図する合理的なパラメータを決定するのが困難であり，実用的な出穂予測モデルの作成は難しい．

このような背景から，発育ステージの予測モデルは，出穂予測やそれによる登熟の最適化には，現場である農地においてあまり使用されず，稲の発育に関する研究結果は現場における応用が難しい，と考えられる．

そこで，次に，本研究では，NN を用いて，移植日と気温・日長のデータから出穂日を予測し，それに基づく登熟期の最適化を行い，その結果の妥当性を検討した．

第 2 章 稲の生理

2-1 稲の発育史

稲の発育史は，次のようになる．稲の種粃が発芽し，葉や分げつの分化・成長が始まり，苗を田へ移植する．やがて幼穂が分化し，穂ばらみ・出穂を経て，開花する．自家受精により，受精すると登熟・結実し，成熟した後，収穫となる．発芽してから成熟するまでの期間は 3～6 ヶ月となる．また，発芽から幼穂分化期までを栄養成長期，幼穂分化期から成熟期までが生殖成長期と呼ぶ．前者は主に，葉・茎など，稲そのものを形成し，後者は主に種実の形成・成長が行われる．また，米の品質と食味には，稲の生殖成長期における登熟環境が深く関与している．本研究では，米の品質向上のため，登熟環境の最適化を目指す．




図 2-1 稲の生育史

2-2 登熟期

(1) 登熟期

受精後，玄米がつくされる過程を登熟という．また，開花から収穫までの期間を登熟期という．登熟期は出穂までの成長で生産された光合成産物を，玄米に集積させる期間である．登熟の長さは，品種や栽培時期で異なるが，おおよそ寒地で45~55日，暖地で30~35日であるとされている．

受精後，子房が成長して玄米の基本的な形態をつくり，玄米の形が大体整うと，デンプンの蓄積が始まる．デンプンの蓄積過程は，乳熟期，糊熟期，黄熟期，完熟期に分けられる．

乳熟期は，デンプン蓄積過程の初期で，胚乳内に高粘度の炭水化物が蓄積しており，指で潰すと中から白い乳汁が出てくる．糊熟期は，デンプンの蓄積が進み，玄米が粳殻内いっぱい成長する頃で，指で粳を押すと，弾力があり，つぶれて糊状となる．黄熟期は粳殻が黄緑色から黄色に変化する頃で，胚乳の水分が減り，粒が硬くなる．完熟期は，胚乳は水分が減って，透明になり，登熟が完了する．

(2) デンプン，たんぱく質の蓄積

葉でつくられた光合成産物は，主に水に溶けたショ糖の形で穂に送られる．穂に光合成産物が送られることを転流と呼ぶが，この光合成産物は，出穂前に生産されたものと出穂後に生産されたものとは異なる．出穂前に生産されたものとは，出穂までに節間や葉鞘にデンプンとして蓄積されていたもので，主に登熟初期に穂に転流し，玄米の初期成長を促し，稈実粳割合を向上させる．出穂後に生産されたものとは，登熟期間に行われる光合成産物で，玄米を充実させ，登熟歩合を向上させる．

ところで，デンプンは開花後5~6日目頃から急速に集積さ

れ、開花後 20 日目頃に最大量に達し、以後一定となる(松尾ら、稲学大成第二巻)。この貯蔵物質の生成を行う反応には、温度の影響が強くこれまで多くの報告がなされている。登熟の温度による影響は、古くからなされ、近年では寺島ら(2001)が、高温が米の品質に与えた影響を明らかにしている。松島・和田ら(1958,1959)は粳のデンプン含有量の増加は 17~29℃の範囲で高温ほど転流量が多いことを示した。また、デンプン同様にたんぱく質の集積についても多くのことが明らかになっており、開花後 5 日目以後に集積が急速に行われ、20 日に最大となる。たんぱく質の生成においては窒素の供給と関係が深いとされている。

2-3 各実験区で栽培されていた品種

今回は、各実験区で異なる品種が栽培されていたので、その特性について述べておきたい。

(1)上流部：ヒノヒカリ

水稻品種”ヒノヒカリ”は、福岡県で 1989 年に奨励品種として採用された。その特性は、他の品種と比較して耐病性や耐伏性に劣るものの、”コシヒカリ”並みの食味を備えた品種である。また、稲-麦の二毛作体系の中に組み込むことのできる中生品種であるため、九州地域における主力品種となるものと期待され、1992 年度現在では、山麓から一般平坦地を中心に 13,226ha で栽培が行われている。県内水稻作付面積では約 1/4 を占めている。(福島ら、1991)

(2)中流部：つくしろまん

水稻品種”つくしろまん”は、早生、食味が優れる、収量性及び玄米品質が同じ熟期の”日本晴”と同程度であるという特性を有する。福岡県では、良食味品種の栽培面積の拡大に努

めてきた。その結果、極早生の”夢つくし”と中生の”ヒノヒカリ”に作付が集中し、この 2 品種で県内水稲の作付面積の 80% に達した。このような作付品種の偏りは気象災害からの危険分散の点で問題である。そこで、早生の良食味品種の育成が不可欠であったため、福岡県農業試験場で 2002 年に早生で良食味品種の”つくしろまん”を育成した(浜地ら, 2003)。

(3)下流部：ミネアサヒ

水稲品種”ミネアサヒ”は極早生の短強稈で良食味の特性を有する。また、山間地から山麓地での栽培に適していることが明らかになった(小宮ら, 1984)。

福岡県では 1984 年 3 月に準奨励品種となっている。

第 3 章 出穂予測モデル

3-1 既存の発育予測モデル

(1) 気温による予測モデル

1) 積算温度法

気温を積算することで作物の発育状況や出穂や開花などの発育ステージへの到達を予測する手法のことであり、積算し、利用する気温データの捕らえ方によって以下のように分類される。

① 単純積算温度法

単純積算温度法では、作物の発育速度は 0°C 以上の日平均温度に比例する、という仮定し、日平均気温の積算値を求める。この積算値が一定値に達すると対象の作物が出穂や開花、収穫などの発育ステージ到達したと考え、作物の発育状況を予測する。

単純積算温度
$$SAT = a \sum T$$

発育速度 $K = aT$
ただし、 a : 定数 T : 0°C 以上の日平均気温




図 3-2 出穂予測モデル

② 有効積算温度法

有効積算温度法では、作物の発育速度は発育が停止する、発育零点の温度以上の日平均温度に比例すると仮定し、日平均温度から発育零点の温度を引いたものの積算値を求める。この積算値が一定値に達すると対象の作物が出穂や開花、結実などの発育ステージ到達したと考え、作物の発育状況を予測する。

発育零点の温度決定には，(i)作物群について大まかに決められた基準温度を用いる方法，(ii)計測したデータを直線の方程式に当てはめ，最小二乗法によって最適値を求める方法がある．予測精度は(ii)が高いが，このとき求まる発育零点の温度は計算上の基準温度であり，作物が低温により，発育を停止する限界温度ではない．

有効積算温度

$$EAT = a \sum (T - D)$$
 発育速度 $K = a(T - D)$
 ただし、 a ：定数、 D ：生育零点の温度、
 T ：日平均気温




図 3-2 出穂予測モデル

③ 発育の下限温度と上限温度を設定する積算温度法

発育の下限温度と上限温度を設定する積算温度法では，発育下限温度(L)と発育上限温度(U)を設定し，作物の発育速度は， $L^{\circ}\text{C}$ 以上 U 以下の日平均気温，もしくは日最高・最低気温に比例する，と仮定し，気温から L を引いた値の積算値を求めることで作物の発育状況を予測する．

有効積算温度

$$EAT = a \sum T \quad \text{for } L < T < U$$
 発育速度
$$K = \begin{cases} 0 & \text{for } T < L \\ a(T - L) & \text{for } L \leq T < U \\ 0 & \text{for } U \leq T \end{cases}$$

 ただし a ：定数、 T ：日平均気温，また
 日最高・最低気温




図 3-3 出穂予測モデル

④ 重回帰式を用いた積算温度法

積算温度法において重回帰式を導入する方法では，發育速度は發育時期別などによって区分した気温と比例すると仮定し，一区画ごとの気温の積算から，対象の作物が出穂，結実などの發育ステージへの到達を予測する．

$$\text{發育速度 } K = a_1T_1 + a_2T_2 + a_3T_3 + \cdots + a_nT_n$$

ただし a : 定数 T : 生育時期別等によって区分された温度

表 3-1 麦類の出穂期予測式

品 種 名	推 定 式
ヒノデハダカ	$Y=0.40X_1+0.03X_2-0.10X_3-0.02X_4+12.21$
イシュクシラズ	$Y=0.94X_1-0.10X_2-0.02X_3-0.13X_4+30.17$

注) Y : 出穂期， X_1 ， X_2 ， X_3 ， X_4 はそれぞれ 11 月，12 月，1 月，2 月の日平均温度の積算値

⑤ 非線形の関数により發育速度を求める方法

気温—發育速度の関係を非線形関数によって表現する．適切な関数形を用いることで高精度の予測が可能である．しかし，予測精度は使用する関数形の種類に依存し，また，作物の種類や品種，栽培地域，栽培時期など諸条件に対し，どのような関数形を選択すべきかの明確な基準がないため，現状では，現場に非線形関数による予測式を導入するのは難しい．

図 3-4




図 3-5




図 3-6





図 3-7



出穂予測モデル

ただし, a , b , c : パラメーター, T : 日平均気温

⑥ 非線形の関数により開花, 出穂日を予測する方法(温度変換日数法)

アレニウスの法則を作物等に適用した方法であり, ある温度での発育日数を標準温度における日数に変換したもの。(金野ら,1986) 気温データのみで地域別, 年次別に発育速度の予測が可能である。主に, 花の開花予測, 果実の発育予測などに用いられる。

(具体例) 温度変換日数法による果実発育の解析 (小野ら,1989)

年次別の果実の発育量変化を温度変換日数(DTS)に対してプロットし,
同一の生長曲線に重ね合わさるように感温特性値を定める。

$DTS = \exp(Ea(T - Te)/(R T Te))$ アレニウスの法則

Ea : 感温特性値 R : 気体定数 T : 絶対温度

Te : 標準温度の絶対温度

$W = A/(1+B \exp(-C t))$ $B = -1+A/W_0$ ロジスティック曲線

A : 最大発育量, B : A と W_0 による定数,

C : 発育速度定数, t : 発育日数 $\rightarrow DTS$ を代入,

W : 果実発育量, W_0 : W の初期値,

(2) 気温と日長による予測モデル

2-1 既存の気温と日長による予測モデル

1) 堀江らのモデル(1986)

堀江らのモデルでは, de Witらの発育速度の概念に基づき, 稲の幼穂分化, 出穂, 成熟などの発育現象は, これらの現象に向けたある量的変化が進行し, その変化の積算値が一定値になる時, 質的变化として発現する, と考える.

この量的変化の進行速度を発育速度(DeVelopmental Rate, DVR)とし, その積算値を発育指数(DeVelopmental Index, DVI)とする. すなわち両者の関係は,

$$DVI = \int_0^n DVR \, dt \cong \sum_{i=0}^n DVR_i \quad (\text{式 3.1})$$

と表せる. ここで, DVR_i は出芽後 i 日目の発育速度, DVI は出芽後 n 日目の発育指数である.

このモデルでは, 出芽, 出穂, 成熟などの各発育段階に, 例えば $a, b, c, \dots (a < b < c < \dots)$ なる任意の数値を与えることにより発育段階を数量的に表すことができる.

このモデルでは, 出芽時を $DVR=0$, 出穂時を $DVR=1$, 成熟時を $DVR=2$ とし, 1日あたりの発育速度 DVR と日長(可照)

時間 L ，日平均気温 T の関係を次の式で表す．

$$DVR = \begin{cases} \frac{1}{G} \cdot \frac{1}{1 + \exp\{-A(T - T_h)\}} & (DVI < DVI^*) \\ \frac{1}{G} \cdot \frac{1 - \exp\{B(L - L_c)\}}{1 + \exp\{-A(T - T_h)\}} & (DVI \geq DVI^*, L < L_c) \\ 0 & (DVI \geq DVI^*, L \geq L_c) \end{cases} \quad (\text{式 3-2})$$

ここで， G ， T_h ， L_c ， A ， B および DVI^* はパラメータであり，それぞれ次のような意味を持つ． G はある品種の出穂までの最小日数， T_h はある日長条件下で発育速度が最大値の1/2になる温度， L_c は限界日長， A は温度係数， B は日長係数， DVI^* は日長に感応し始める発育指数である．これらのパラメータは出芽～出穂日数とそれに対応した日平均気温と日長のデータを用いて，最小二乗法によって決定する．この際，パラメータの値の反復改良のアルゴリズムはシンプレックス法を用いる．

2) 川方らのモデル(1987)

水稻の予測モデルについての比較を行う．2ヵ年の作期移動試験(4～7月)を行い，播種から幼穂形成期にいたるまでのDVRを表す5種類のモデル(表)について適合性を検討した．

表 3-2 予測を用いた DVR のモデル

種類	DVR 式
(1)	$a(T - b)$
(2)	$[1 - \exp\{-a(T - b)\}]/c$
(3)	$aT + bL + c$
(4)	$a(L - b)(T - c)$
(5)	$\frac{[1 - \exp\{a(L - b)\}]}{e[1 + \exp\{-c(t - d)\}]}$

但し， a ， b ， c ， d ， e ：パラメータ， L ：日長時間， T ：日平均

気温

3) ノンパラメトリック法

ノンパラメトリック法では発育過程を先に述べた堀江らの DVI の概念(1986)に従い, DVR をノンプレックス平滑化手法を用いて行う. 作物と環境要因との関係は複雑であり, 発育速度を単純な関数で求めると, 予測誤差が生じやすい. しかし, ノンパラメトリック法は, 発育速度や環境要因に関係なく用いることができ, より弱い仮定にて行うので精度の高い発育ステージの予測が可能である. ノンプレックス法は, DVR を発育期間中の毎日の平均気温に対し, 任意の温度刻み毎に決定する.

$$DVI = \sum DVR(T) \\ DVR(T) = DVR_j \quad \text{for } T_0 + j\Delta T \leq T < (j+1)\Delta T \quad (0 \leq j \leq M-1) \quad (\text{式 3-3})$$

DVR_j : 一定の温度範囲毎の DVR, j : 任意の自然数, $0 \leq j \leq M-1$ (M は日平均気温の刻みの数), T_0 : T の最小値よりも小さな値, $T_0 + M\Delta T$: T の最大値よりも大きな値, ΔT : 日平均気温の刻みの幅

以上を元に, 各種データ組に対して, $\sum_{i=1}^D DVR(T_i) = 1$ (D は出穂日) がよい近似で成立するように $DVR(T)$ を決定する.

3-2 堀江らのモデル(1986)による出穂予測

2-1, ①にて記した, 堀江らのモデル(1986)を基に, 出穂予測モデルの作成を行う. 具体的手順としては, 使用するモデルは概念は堀江らのモデルと同様だが, 相違点として, 移植時の DVR を 0, 出穂時の DVR を 1 とし, DVR=1 となるまでの日数を計算する. モデルの持つ 6 種類の移植・出穂データを用いて, モデルを最小二乗法にて最適化し, パラメータを決定する. パラメータの更新方法は, 最急降下法, シンプレ

ックス法，GAにて決定する．用いる，移植日と出穂日のデータは，福岡県農業総合試験場内本場(1988～1992, 1993, 1995～2007)，豊前分場(1985～1990, 1993, 1997～2001, 2002)，筑後分場(1993, 2007)と本研究の対象フィールドである星野村(2007)において計測されたものである．気温のデータは，星野村については調査水田の計測値，試験場については最寄りの気象台の計測値を使用する．日長のデータは天文日長を用い，星野村の日長は，山間地であるので周囲の勾配による地形データを考慮して作成する．

(1)最小二乗法

最小二乗法とはパラメータが未知の関数に対し，適当な初期値を与え，関数による理論値と実測データの値との誤差を求める．具体的手順は以下のようになる．

まず，最適化の対象式 $h=f(x)$ に対し，パラメータに適当な初期値を与え，実験・観測等から実測データを L 組用意する．データを $h=f(x)$ に代入し，その理論値と実測値の差異を求め，

合計する． $(E=\sum_{l=0}^L(y_{(l)}-h_{(l)})^2)$

この E を基に，評価関数 S を作成し， S が最小となるようにする．(通常， $S=E$ もしくは $S=\text{sigmoid}(-E)$ など)

(2)勾配法(最急降下法)によるモデルパラメータの決定

1)勾配法(最急降下法)

勾配法とは，最小二乗法や NN 等におけるパラメータ最適化

の手法の一つであり，評価関数 $S=E=\sum_{l=0}^L(y_{(l)}-h_{(l)})^2$ とし， S が最

小となるようなパラメータを，評価関数 S の勾配 $\frac{\partial S}{\partial \theta}$ を用いて，

パラメータ $\theta^{(j)}$ (j は更新回数であり $\theta^{(0)}$ は初期値)を更新する。
 名称通り，勾配に沿って降下しながら，最小となる部分を探索するため，探索の結果，最小値ではなく，極小値に陥りやすく，探索の成功と探索結果の信頼性は初期値に依存する。




図 3-8 評価関数




図 3-9 評価関数

N 個のパラメータを持つ評価関数 S における更新の一般式

$$\theta_n^{(j+1)} = \theta_n^{(j)} - K \cdot \frac{\partial S(\theta^{(j)})}{\partial \theta_n} \cdot \frac{1}{\left| \frac{\partial S(\theta^{(j)})}{\partial \theta} \right|} \quad (\text{式 3-4})$$

ただし， j : パラメータの更新回数 ($\theta^{(0)}$ は初期値)， K : 更新速度， n : パラメータの識別番号 ($1 \leq n \leq N$)， $s(\theta^{(j)})$: 評価関数， $\theta_n^{(j)}$: j 回更新された， n 番目のパラメータ

3) 勾配法によるパラメータ決定の結果と考察

勾配法により，出穂予測モデルのパラメータの最適値を求める．この実験においては，移植・出穂のデータは堀江らの研究論文から用いる．また，誤差は日数換算のため，誤差 E をデータ数で割ったものの平方根を表記する．初期値は堀江らの研究論文における探索結果から実行する．結果を以下の表に示す．

実験，勾配法の特性から，この手法は初期値への依存が高いため，極小値に陥りやすく，出穂予測モデルの最適化には不向きである．

また，最適化する関数 S は多峰性に富む，と考えられる．

表 3-3 勾配法によるパラメータ決定

パラメータ	A	Th ($^{\circ}\text{C}$)	B	Lc (hours)	G (days)	DVI*	誤差 (日)
初期値	0.3504	18.81	0.6736	15.64	51.37	0.2	6.40
結果	0.3498	18.81	0.6734	15.64	51.37	0.2	6.39

(3) シンプレックス法(単体法)によるモデルパラメータの決定

1) シンプレックス法(単体法)

シンプレックス法とは，最小二乗法や NN 等におけるパラメータ最適化の手法の一つであり，評価関数 $S = E = \sum_{l=0}^L (y_{(l)} - h_{(l)})^2$ とする．以下に具体的手法を記す．

まず， S が N 個のパラメータからなる N 次元の関数である時，パラメータとして，それぞれ任意の値 $\theta_n^{(0)}$ ($1 \leq n \leq N$)，及びその値に差分を加えた値 $\theta_n^{(0)} + \Delta\theta_n^{(0)}$ による $N+1$ 組の組み合わせ $\{\theta\}$ を用意する． S に $\{\theta\}$ を代入した，

$s(\theta_n^{(0)}) = s(\theta_1^{(0)}, \theta_2^{(0)}, \dots, \theta_N^{(0)})$ ，と i が $1 \sim N$ の自然数を取る時におけるそれぞれの $s(\theta_1^{(0)}, \theta_2^{(0)}, \dots, \theta_{i-1}^{(0)}, \theta_i^{(0)} + \Delta\theta_i^{(0)}, \theta_{i+1}^{(0)}, \dots, \theta_N^{(0)})$ を求める．この $N+1$ 個の S の値の中で最小・最大をとる θ の組み合わせを調べる．

次に S が最大の時のパラメータの組み合わせ $\max \theta_n^{(j)}$ に対

$$\text{し, } \max \theta_n^{(j)'} = \frac{2 \times \sum_{n=1}^N \theta_n^{(j)} - (N+2) \times \max \theta_n^{(j)}}{N}, \quad (\text{式 3-5})$$

$$\max \theta_n^{(j)''} = \frac{3 \times \sum_{n=1}^N \theta_n^{(j)} - (2N+3) \max \theta_n^{(j)}}{N}, \quad (\text{式 3-6})$$

$$jp \theta_n^{(j)} = \frac{\sum_{n=1}^N \theta_n^{(j)}}{N+1} \quad (\text{式 3-7})$$

を求める．

$\max \theta_n^{(j)}$ と， S が最小の時のパラメータの組 $\min \theta_n^{(j)}$ に対し，

$S(\min \theta_n^{(j)}) \geq S(\max \theta_n^{(j)'})$ の時，

$S(\min \theta_n^{(j)}) \geq S(\max \theta_n^{(j)'}) \geq S(\max \theta_n^{(j)'')}$ ならば，

$\max \theta_n^{(j+1)} = \max \theta_n^{(j)'}$ とし，

$S(\max \theta_n^{(j)'}) \geq S(\max \theta_n^{(j)'')}$ ならば，

$\max \theta_n^{(j+1)} = \max \theta_n^{(j)'}$ とする．

また， $S(\min \theta_n^{(j)}) < S(\max \theta_n^{(j)'})$ の時， $S(\max \theta_n^{(j)}) \geq S(jp\theta_n^{(j)})$ ならば，

$\max \theta_n^{(j+1)} = jp\theta_n^{(j)}$ とし，それ以外は

$\theta_n^{(j+1)} = \frac{\theta_n^{(j)} + \min \theta_n^{(j)}}{2}$ とする．

どの場合にも，当てはまらない場合， $\max \theta_n^{(j+1)} = \max \theta_n^{(j)'}$ とする．

なお， j は更新回数とする．

2) シンプレックス法によるパラメータ決定の結果と考察

シンプレックス法により，出穂予測モデルのパラメータの最適値を求める．この実験においては，移植・出穂のデータは堀江らの研究論文から用いる．また，誤差は日数換算のため，誤差 E をデータ数で割ったものの平方根を表記する．初期値

は堀江らの研究論文における探索結果を用いて実行する．

結果を以下の表に示す．

表 3-4 シンプレックス法によるパラメータ決定

パラメータ	A	Th (°C)	B	Lc (hours)	G (days)	DVI [*]	誤差 (日)
初期値	0.3504	18.81	0.6736	15.64	51.37	0.20	6.4
結果	0.49	18.71	0.68	15.6	51.48	0.23	3.34

(4) 遺伝的アルゴリズムによるモデルパラメータの決定

1) 遺伝的アルゴリズム (GA)

GA においては，評価関数 S は $S = \text{sigmoid}\{1 + \exp(E)\}$, $E = \sum_{l=0}^L (y_{(l)} - h_{(l)})^2$

とする．GA とは，生物の生存競争をコンピュータによる最適解探索に利用する手法である．以下に簡単な手順を記す．なお，ルーレットを回転結果やランダムに行う手順は乱数等によって行う．

- ① ランダムに複数の染色体を作成し，第 1 世代とする．主に，10 進数による実数の列，もしくは 2 進数，グレイコードによる 0, 1 の数列を用いる．変数の取りうる範囲に基づき，染色体をパラメータの候補値に変換する．
- ② パラメータの候補値から評価関数 S を求め， S の値を反映したルーレットを作成する． S の総計に対して高い S の値を持つほど，ルーレットにおいて広い面積を獲得する．これは生物の適者生存に当たる．
- ③ ルーレットを回し，候補値を 2 つ選び，組み合わせを作

る．選ばれた候補値はメンデルの遺伝の法則と同様に，互いの数列を交差させ，次世代のパラメータを作る．また，設定した確率においてランダムに変異を起こす．他にも，一定以上の S の値を得たパラメータはそのまま次世代に使用する(エリート戦略)，多峰性の関数は 1 つの峰に集中しないよう，常に候補値は適度に離散させる(離散化)などの設定をする場合もある．

④ 設定した世代数だけ繰り返し，染色体を改良し，最適なパラメータを探索する．また，終了条件を，誤差 E が一定値以内になる，世代が変わっても最適な候補値が変化しない等にする場合もある．

⑤ 最終世代，もしくは全世代を通して最も高い S の値をもつ候補値を，求める最適パラメータとし，その染色体を変換し，パラメータの値を出力する．

2)GA によるパラメータ決定の結果と考察

GA によって出穂予測モデルのパラメータの決定を行う．GA によるパラメータ決定の結果は表である．交配を繰り返す世代数を 500 世代，1 つの染色体の長さを 60 個の数字，交叉を行う確率を 0.25，突然変異確率を 0.01，1 集団における染色体の 30 体とする．染色体を 2 進数での並びとするバイナリーコード，染色体の交配は 1 つの染色体における交配は 1 回までとする．結果を表に示す．最適な値となったが，このパラメータによる出穂予測は堀江らのモデルの性質上，星野村などの周囲の地形の勾配が激しいところがあるため，日長がモデルの考慮の範囲外であり，より大きな誤差が出てしまい，堀江らのモデルの星野村への適用は不適切である．

表 3-5 遺伝的アルゴリズムによるパラメータ決定

パラメータ	A	Th (℃)	B	Lc (hours)	G (days)	DVI*	誤差 (日)
-------	---	-----------	---	---------------	-------------	------	-----------

結果	0.15	16.26	0.31	18.91	43.78	0.44	1.33
----	------	-------	------	-------	-------	------	------

第 4 章ニューラルネットワーク (NN) の理論

4-1 ニューラルネットワーク (NN) 概説

脳は神経細胞(ニューロン)やグリマ細胞など多数の細胞からなり，人間の脳には約 140 億個のニューロンが存在する．各ニューロンは，多数の他のニューロンから信号を受け取り，また，他の多数のニューロンへ信号を受け渡している．脳は，この信号の流れからなるネットワークによって，様々な情報処理を行っている．

NN とは，このような，生物の持つニューロンとそのつながりからなるネットワークをモデルにした AI(Artificial Intelligence: 人工知能)理論の一つであり，脳機能に見られるいくつかの特性を計算機上のシミュレーションによって表現することを目指した数学モデルである．生物学や神経科学との区別のため，人工ニューラルネットワーク (NN)とも呼ばれる．以下，NN という記述は，人工 NN を指すとする．実際の応用例としては，天気予報や株価の予想などがある．

ニューロネットワーク技術の研究開発は，人間の脳で行われている情報処理のしくみを，生理心理学的，生物物理学，あるいは数学的にいかに解明していくかというところからスタートした．ニューロンに関する研究は 20 世紀初めに既に行われていたが，最初にニューロンの数式モデル化を試みたのはマッカロ (McCulloch) とピッツ (Pitts) である (1943)．以後，ヘブ (Hebb) やラムエルハート (Rumelhart)，マクレランド (McClelland) など多くの研究者によってニューロンネットワーク研究が進んだ．1970 年代半ば以降の AI 研究の高まりとその後の，逐次的・記号処理的な方法のみによる AI 研究の発展の行き詰まりの影響により，人間の並列的・直感的処理

能力をシステムに盛り込む事の可能性が見直された事や，デバイス技術の急速な発達とそれによる計算機の性能が向上した事も NN 研究の進んだ要因である．1980 年代後半からは，米国を皮切りに全世界的に，ニューロ技術に関する国際会議や研究会活動が盛んに行われている．近年，診断システムや認識システム，ロボット技術など従来の技術では実現が困難とされるシステムに応用され，ファジィ理論との融合技術も研究成果が出ている．これらは家電製品にまで応用され，我々の日常でも目に見える形で提供されるようになった．

今回使用した，NN の基本的な考え方は以下のようになる．

我々が教師として，「例題」と「模範解答」を用意し，それぞれを「入力(input)」と「出力(output)」として，NN にその両者間の関係性を学習させる．これを「学習」と言う．この「学習」をもとに，「例題」以外の問題を「入力」として，NN に「出力」として解答を推理させる．

NN の応用例としては天気予報や株価変動の予測などが挙げられる．具体例として，天気予報の NN では，雲の様子や気温，気圧など，当日の気象データから翌日の天気予報予測する場合，とある日の気象データを「例題」とし，その次の日の天候を「模範解答」とする．この「例題」と「模範解答」の組み合わせを多数用意し，NN にその関係性を学習させる．翌日の天候を予測する際は，学習後の NN に当日の気象データを入力し，翌日の天候を解答として得る．

以下に，生物のニューロンとそのネットワークの仕組み，及びその仕組みに基づく NN について説明する．

4-2 NN を構築する素子の構造

(1) 神経細胞(ニューロン)の構造

電気生理学では以下の図のように神経細胞（ニューロン）は働く．なお，樹状突起とは他のニューロンからの信号を受

け取る働きをなす器官，軸索とは細胞本体からの信号を他のニューロンへ伝える，出力用の繊維である．




図 4-1 神経細胞 (ニューロン)

1)ニューロンは，樹状突起によって他の多数のニューロンから入力信号を受け取る．




図 4-2 神経細胞の興奮 1

2)受け取った入力信号によって，そのニューロンの膜電位が定まる．より多くのニューロンからの入力信号を受け取るほど膜電位は高い値をとる．




図 4-3 神経細胞の興奮 2

3)膜電位がそのニューロン固有の閾値以下ならば，ニューロンは何も反応しないが，膜電位が閾値を越えた瞬間，ニューロンは興奮し，内部の電位が高くなる．これにより，0.1V 程度のパルスが発生し，軸索を通じて，他のニューロンへと信号として出力される．



図 4-3 神経細胞の興奮 3

(2) ニューラルの入出力関係の数式モデル化

前節で述べた電気生理学的な生物のニューロン構造を数学的に表現し、数値モデルを構築する。このモデルが、NNにおける、生物のニューロンを模擬する人工のニューラルであり、「素子」と呼ぶ。現在用いられている素子の工学的モデルは2通りの方法で分類できる。1つは、素子の動作が「決定的」であるか、「確率的」であるか、という事である。もう1つは、出力が「2値」であるか「アナログ」であるか、という事である。以下に、これらの観点からNNの素子について説明する。

1) 決定的素子と確率的素子

決定的とは、入力から出力を決定する事が一意である事を意味する。すなわち、決定的素子とは、同じ入力が行われると、常に同じ出力を行う素子を示す。

決定的素子の一例としては、表を示す。表に示す入出力関係を持つ素子では、入力0に対する出力は常に1である。また、入力1に対する出力は常に1である。一方、確率的素子の一例は表となる。表に示す入出力関係を持つ素子では、入力が0の時、出力は0にも1にもなるが、1となる確率の方が0となる確率の方が高い。 $(0.9 > 0.1)$ 同じく、入力が1の時は、出力は0にも1にもなるが、1となる確率は0となる確率よりも低い。 $(0.2 < 0.8)$ 出力を決定するには、サイコロや適当な乱数を示す関数などを用いる。このように、出力が確率に支配され、入力に対し一定でない素子を確率的素子という。

なお、厳密に考えると、生物の脳にあるニューロンは、細胞内の電位が常に揺らいでおり、細胞体が興奮するのに必要とする入力が一定でないため、確率的素子の一種とみなせる。

そのため，入力が 0 であっても自発的に興奮し，インパルスが発生する可能性があり，逆に強い興奮性の作用があっても興奮が発生しないことがある．

表 4-1 決定的素子の
入出力関係の一例

入力	出力
0	1
1	0

表 4-2 確率的素子の入出力の
一例


入力	出力が 0 となる 確率	出力が 1 となる 確率
0	0.1	0.9
1	0.8	0.2

2)2 値モデルとアナログモデル

ニューロンが興奮するかしないか，というニューロンの出力形式は，ニューロンが外部へ 2 通りの作用しか及ぼさない・0 か 1 かの出力しかしない，という解釈ができる．このような観点からニューロンをモデル化したものが 2 値モデルである．この場合，作用はあるかないかの 2 通りしかなく，中間的作用を及ぼし得ないのでニューロンの全か無かの法則に従う．一方，インパルスの発生頻度，すなわち細胞が每秒何回興奮するかという観点から解釈すると，ニューロンの出力はアナログ値である．この場合，ニューロンの膜電位(s)と出力(インパルス頻度)(y)の関係は図に示すグラフにより表される．これにより，膜電位が閾値(θ)に到達しない中間的段階においても，他のニューロンへその影響を与えることができる．なお，図において，膜電位が 0 の際もインパルスが発生しているのは，前述したように，生物のニューロンは確率的素子であり，自発的興奮が発生しうるためである．

このモデルでは，一見，ニューロンにおける「全か無かの法則」に矛盾するようだが，インパルス頻度という別の視点からニューロンの動作を捉えているために中間的作用が働くよう

に見えるだけで，インパルスのここに対しては「全か無かの法則」が成立している．



また，図に示される S 字状の飽和関数はシグモイド関数と呼ばれており，ニューロンの入出力特性を表す重要な関数である．素子の動作は次式で表されるシグモイド関数を用いることが多い．

$$y = \text{sigmoid}(s - \theta) \quad (\text{式 4-1})$$

$$\text{sigmoid}(z) = \frac{1}{1 + e^{-\alpha z}} \quad (\text{式 4-2})$$

θ : 閾値, α : ゲイン

式の α は「ゲイン」と呼び，ゲインの大小により，シグモイド関数は図中に示されるように形を変える．




図 4-4 シグモイド関数

3) 素子のモデルの種類


主に，NN にて用いられている代表的な素子 4 種類を紹介する．また，4 種類の内，本研究にて使用したモデルは決定的アナログモデルである．決定的アナログモデルについてはその構造と特徴，入出力に関する計算手続きの詳細を記す．

① 決定的アナログモデル

本研究では，素子として決定的アナログモデルを使用する．このモデルは，名称にあるように，一定の入力値に対し，常に一定の値を出力し，また入力信号により決まる膜電位から出力を 0～1 のアナログ値として決定する．

このモデルの構造と入出力の関係式は次のようになる．

図 4-5 決定的アナログモデル



$$S = \sum_{n=1}^N w_n x_n \quad (\text{式 4-2})$$

$$y = \text{sigmoid}(s - \theta) \quad (\text{式 4-3})$$

$$\text{sigmoid}(z) = \frac{1}{1 + e^{-\alpha z}}$$

(式 4-4)

このモデルにおける出力の計算手続きの具体的なプロセスは以下になる。

I他の素子，あるいは外部からの入力信号がモデルに入力される．これらの入力を $\{x_1, x_2, \dots, x_n\}$ とする．これに重み $\{w_1, w_2, \dots, w_n\}$ を掛け，加え合わせ，膜電位に相当する量 s を得る．重み $\{w_1, w_2, \dots, w_n\}$ は，それぞれ対応する入力信号に掛け合わされる事で，各入力信号が膜電位や出力へ与える影響度合いを調節する．また，詳細は後述するが，NNが学習により最適化される際，NNはこの重み $\{w_1, w_2, \dots, w_n\}$ の値と閾値を調節することで対応する．




図 4-6 決定的モデルの計算手順 1

II Iで求めた膜電位の値 s から出力を計算する．アナログモデルであるため，出力 y は膜電位 s と閾値 θ からシグモイド関数を用いて，連続的な値として算出する．シグモイド関数の α は，ゲインと呼び， α の値が大きくなるほど，S字状関数の勾配が急になり，小さくなるほど，勾配は緩やかになる．

α の値の調節により， θ 付近における出力 y の膜電位 s に対する変化の勢いを変更できる．




図 4-7 決定的モデルの計算手順 2

Ⅲ I Ⅱを基本にして，計算式上にて重み $\{w_1, w_2, \dots, w_n\}$ と閾値 θ を統一すると，ニューロンの閾値が結線の重みのひとつとして扱える．これにより，重み修正手続きが閾値の修正手続きをも与えることができる．

(i) 入力 $\{x_1, x_2, \dots, x_n\}$ へ常に 1 の値を取る入力 x_0 を加える．また， x_0 に対する重み w_0 の値を $-\theta$ とする．




図 4-8 決定的モデルの計算手順 2

(ii) 膜電位 s を求める式の、 Σ における n が取る値を $1 \sim N$ から 0 から N に変えると、次のように、閾値が入力とその重みの一部となり、出力を求める式 y における閾値 θ を引く作業を省略することが可能となり、式 1 と式 2 の組み合わせが、式 3 となる。式 2 は式 3 における $n=0$ の値に等しい。この作業を行う事で、今まで学習において重み $\{w_1, w_2, \dots, w_n\}$ と閾値 θ をそれぞれ修正していた状態から、重み $\{w_0, w_2, \dots, w_n\}$ のみを修正することとなる。これにより、修正作業が一括されるため、計算式とそれに基づく NN のプログラムの構造が簡易なものとなる。

$$\begin{cases} S = \sum_{n=1}^N w_n x_n \\ y = \text{sigmoid}(s - \theta) \end{cases} \quad (\text{式 4-8})$$

$$\rightarrow y = \text{sigmoid}\left(\sum_{n=1}^N w_n x_n - \theta\right) \quad (\text{式 4-9})$$

$$\rightarrow y = \text{sigmoid}\left\{\sum_{n=1}^N w_n x_n + 1 \times (-\theta)\right\} \quad (\text{式 4-10})$$

$$\rightarrow y = \text{sigmoid}\left\{\sum_{n=1}^N w_n x_n + x_0 w_0\right\} (\because x_0 = 1, w_0 = -\theta) \quad (\text{式 4-11})$$

$$\rightarrow y = \text{sigmoid}\left\{\sum_{n=0}^N w_n x_n\right\}$$

(式 4-12)

$$\rightarrow \begin{cases} S = \sum_{n=0}^N w_n x_n \\ y = \text{sigmoid}(s) \end{cases} \quad (\text{式 4-13})$$

$$S = \sum_{n=1}^N w_n x_n \quad (\text{式 4-14a})$$

$$\begin{cases} w_0 = -\theta \\ x_0 = 1 \end{cases} \quad (\text{式 4-14b})$$

$$S = \sum_{n=0}^N w_n x_n \quad (\text{式 4-14c})$$




図 4-9 決定的アナログモデル

② 決定的 2 値モデル

ニューロンを，興奮するかしないかに対応して $\{0, 1\}$ の 2 値の出力を持つ決定的素子によってモデル化したものである．素子における入出力モデルを式によって表現すると以下のようになる．

$$s = \sum_{n=1}^N w_n x_n \quad (\text{式 4-15})$$

$$y = \begin{cases} 1 & s \geq \theta \\ 0 & s < \theta \end{cases} \quad (\text{式 4-16})$$

まず，他の素子，あるいは外部から与えられる信号をモデルに入力する．これらの入力を $\{x_1, x_2, \dots, x_n\}$ とする．これにそれぞれ対応する重み $\{w_1, w_2, \dots, w_n\}$ を掛け，加え合わせ，膜電位に相当する s を決定する．重み $\{w_1, w_2, \dots, w_n\}$ はシナプス結線重みに該当する．膜電位 s が閾値 θ を超える時，出力 y を 1 とする．閾値以下の場合，出力 y は 0 とする．

③ 確率的 2 値モデル

出力 y は $\{0, 1\}$ の 2 値を取る．出力値が 0, 1 のどちらをとるかについては次の式により確率的に定める．

$$s = \sum_{n=1}^N w_n x_n \quad (\text{式 4-17})$$

$$p = \text{sigmoid} (s - \theta) \quad (\text{式 4-18})$$

$$P(y = 1) = p \cdot P(y = 0) = 1 - p \quad (\text{式 4-19})$$

まず，決定的モデルと同様の方法で入力から膜電位 s を計算する． s に対して $p = \text{sigmoid}(s - \theta)$ を計算し，出力 y を p の確率で 1， $1 - p$ の確率で 0 とする．プログラミングにおける確率的モデルの計算には擬似乱数を用いて計算する．




図 4-10 確率的アナログモデル

上の図のように，膜電位 s が高くなるにつれて p が大きくなり，出力が 1 となる確率が高くなる．

④ 時間発展モデル

時間発展モデルはホップフィールド型 NN の構成素子として利用される．前述の 3 つのモデルが膜電位の特定時点の固定した値を扱っているのに対して，このモデルでは，膜内電位の時間変化を扱う．時間発展モデルの名称はこの事実に基づく．

時間発展モデルでは，膜電位 s の時間変化を次の微分方程式で記述する．

$$\frac{ds}{dt} = -s + \sum_{n=1}^N w_n x_n$$

(式 4-20)

この式に従って時間変化する膜電位を用いて，素子の出力 y を次式で計算する．

$$y = \text{sigmoid}(s - \theta) \quad (\text{式 4-21})$$

この微分方程 $\sum_{n=1}^N w_n x_n$ 式は の値が正負いずれの場合も，次式が成り立つ 時， $ds/dt=0$ となり， s の値は平衡して変化しなくなる．

$$s = \sum_{n=1}^N w_n x_n \quad (\text{式 4-22})$$

なお，コンピュータ内の計算では，式を次のように離散時間化した近似式とする場合がある．ここで ε は十分小さな正の数である．

$$\triangle s = \varepsilon \left(-s + \sum_{n=1}^N w_n x_n \right) \quad (\text{式 4-23})$$

$$s = s + \triangle s \quad (\text{式 4-24})$$

(3) NN の構造

脳の構造は，ニューロン同士が繋がり，他のニューロンからの信号を受け取り，他のニューロンへと流すことで，信号の流れが起き，脳の機能が形作られる．同じく，NNでは，図のように，各素子が接続し，他の素子から信号を受け取り，他の素子へ信号を流すことにより，信号の流れから成るネットワークが構成される．赤字にて示される各素子は入力素子(入力ユニット)と呼び，外部からの信号を受け取り，ネット

ワークへと入力信号を伝播させる．また，青字にて示される各素子は出力素子(出力ユニット)と呼び，外部へと信号を出力し，これが NN の計算結果となる．また，図のように階層構造であり，多層である場合，入力素子によって構成されている層を入力層と呼び，出力素子によって構成されている層を出力層と呼ぶ．入力層と出力層の間にある，黒字の素子によって構成される各層は中間層と呼ぶ．




図 4-11 ニューラルネットワーク

1) NN の形態

ニューロン同士が繋がり脳の機能が形作られるのと同じく，各素子が接続し，

NN が構成されるが，接続の形式によるネットワークの形態には，パーセプトロン，ホップフィールドネットワーク，フィードフォワード型，リカレント型など多数の種類が存在するが，今回は代表的なフィードフォワード型とリカレント型について記す．

① フィードフォワード型

図に示すように素子を接続したモデルをフィードフォワード型 NN と呼ぶ．このモデルでは信号が入力側から出力側に向けて 1 方向に流れていく．そのため，ネットワークの入力側の素子の値を指定すると，そこから出力側へ向けて素子の値を次々と決めることができる．




図 4-12 フィードフォワード型

② リカレント型

リカレント型 NN は，図に示すように，入力側の素子に出力側素子からの信号がフィードバックするように接続する．入力側，出力側の素子は相互に依存しあっており，時間的に値を決めていく素子群にて構成される．相互依存型 NN とも呼ぶ．




図 4-13 リカレント型

(4) NN の学習

1) NN の学習と学習則

NNはただ作成しただけでは，適切な出力結果を示すことはできない．対応する出力が未知である入力に対し，適切な値を出力として算出するには，まず，パラメータである，重み $\{w_0, w_1, \dots, w_n\}$ に適当な初期値を与え，それを元に，入力から出力へ信号を流し，次に，その際に生じる，目標との誤差を最小にし，希望する出力を得るべく，パラメータを最適化する必要がある．この作業を学習と呼び，学習を行うための方法を学習則と呼ぶ．この学習作業の繰り返しからなる最適化によって，NNは，結果が未知である入力に対し，適切な出力が可能となる．

学習則は教師付き学習と教師無し学習の 2 種類がある．教師付き学習は幾つかの入力と各入力に対する目標出力を用意し，NNによる実際の出力が目標に一致するよう重み $\{w_0, w_1, \dots, w_n\}$ を調節する学習則であり，教師無し学習は目標出力ではなく，別に与えられた規則に従って重み $\{w_0, w_1, \dots, w_n\}$ を調節する．

本研究では学習則として誤差逆伝搬法を用いる．そこで，誤差逆伝搬法について説明する．

2) 誤差逆伝搬法 (Back Propagation : BP 則)

図に示すように素子を接続したモデルをフィードフォワード型 NN と呼ぶ．このモデルでは信号が入力側から出力側に向けて 1 方向に流れる．誤差逆伝搬法はフィードフォワード型 NN における学習則のひとつである．誤差逆伝搬法によるフィードフォワード型 NN の最適化を行う際には，パラメータである重み $\{w_0, w_1, \dots, w_n\}$ の初期値と，以下に説明する学習回数 P ，学習係数 ε ，慣性係数 α ，および中間層の全層数と

各層における素子数を設定する必要がある．




図 4-14 誤差逆伝搬法

ネットワークに対し，パラメータである結線の重みそれぞれに適当な初期値が与えられ，また，入力 $(a_1^{(l)}, a_2^{(l)}, \dots, a_N^{(l)})$ ，目標出力 $(t_1^{(l)}, t_2^{(l)}, \dots, t_M^{(l)})$ ($1 \leq l \leq L$) という入出力関係である， L 組のデータが学習目標として与えられるとする．この時，入力 $(a_1^{(l)}, a_2^{(l)}, \dots, a_N^{(l)})$ に対する，実際の出力は $(y_1^{(l)}, y_2^{(l)}, \dots, y_M^{(l)})$ であるとする，目標出力と実際の出力の誤差の度合いを表す尺度として，誤差評価尺度 E が与えられるので， E が小さくなるようにネットワーク内部の結線の重みを修正する．

修正の手法には，学習目標として与えられる全教師データを一括して用い，一度にパラメータを修正する手法と，教師データが 1 つ与えられるたびにパラメータを修正する手法があり，前者を一括更新学習法，後者を逐次更新学習法と呼ぶ．

一括更新学習法は手法の特性上，毎回の修正における誤差縮小は確実性が高いが，全教師データに対する誤差を記憶してから処理するため，実用が困難である．また，逐次更新学習法は教師データ 1 組ごとに処理を行うため，厳密性は損なわれるが，NN においては実用性が高い手法である．両者における誤差評価尺度 E はそれぞれ次の式のようになる．

$$\text{一括更新学習法} \bullet E = \sum_{l=1}^L E^{(l)} = \sum_{l=1}^L \sum_{i=1}^M |y_i^{(l)} - t_i^{(l)}| \quad (\text{式 4-25})$$

$$\text{逐次更新学習法} \bullet l\text{番目の教師データにおいて} E^{(l)} = \sum_{i=1}^M |y_i^{(l)} - t_i^{(l)}|^2 \quad (\text{式 4-26})$$

誤差逆伝搬法は逐次更新学習法であるので教師データ 1 組ごとに，勾配法の原理を用いて重みを修正し，これを全教師データにおいて行う．この作業を 1 回の学習として，設定した回数だけ学習を繰り返す．

重み w_i の修正式は次のように表せる．なお，用いる教師データは l 番目 $(a_1^{(l)}, a_2^{(l)}, \dots, a_N^{(l)})$ ， $(t_1^{(l)}, t_2^{(l)}, \dots, t_M^{(l)})$ とし，逐次更新学習においては一回の修正内では教師データの識別は必要としないので右肩の (l) は省略する．

$$\Delta w_i = -\varepsilon \frac{\partial E}{\partial w_i} \quad (\text{式 4-27})$$

$$w_i(p) = \alpha \cdot w_i(p-1) - \varepsilon \cdot \frac{\partial E}{\partial w_i} \quad (\text{式 4-28})$$

$$\frac{\partial E}{\partial w_{ji}^{(h+1)}} = \frac{\partial E}{\partial S_i^{(h+1)}} \cdot y_j^{(h)} \quad (\text{式 4-29})$$

ただし, $w_{ji}^{(h+1)}$: 第 h 層の第 j 素子から第 $(h+1)$ 層の第 i 素子へおける結線の重み

p : 学習した回数 (修正した回数: $1 \leq p \leq P$)

P : 学習回数(パラメータとして設定する, 学習を行う回数)

$S_i^{(h+1)}$: 第 $(h+1)$ 層の第 i 素子の膜電位 s

w_i : $w_{ji}^{(h+1)}$ を略記したもの

$w_i(p)$: p 回, 修正された w_i ($w_i(0)$ は w_i の初期値とする)

$y_j^{(h)}$: 第 h 層の第 j 素子からの出力 y

α : 慣性係数(修正前の重み $w_i(p-1)$ の変化による影響を調節する)

ε : 学習係数(学習速度を調節する)

であるとし, また, $1 < h < R$ において, 第 0 層は入力層, $y_j^{(0)} = a_j$ (a_j は第 j 番目の入力データ)とし, 第 $(R+1)$ 層は出力層とする.

$$y_j^{(0)} = a_j \quad (\text{式 4-30})$$

$$\frac{\partial E}{\partial w_{ji}^{(1)}} = \frac{\partial E}{\partial S_i^{(1)}} \cdot a_j \quad \begin{array}{l} a_j \text{は第 } j \text{ 番目の入力データ} \\ (1 < j < L) \end{array} \quad (\text{式 4-31})$$

$$\frac{\partial E}{\partial w_{ji}^{(\text{出力層})}} = \frac{\partial E}{\partial S_i^{(\text{出力層})}} \cdot y_j^{(R)} \quad (\text{式 4-32})$$

また, 第 $(h+1)$ 層の素子数を K とすると

$$\frac{\partial E}{\partial S_j^{(h)}} = \text{sigmoi } d'(S_j^{(h)}) \cdot \sum_{i=1}^K \left(\frac{\partial E}{\partial S_i^{(h+1)}} \cdot w_{ji}^{(h+1)} \right) \quad (\text{式 4-33})$$

であり, 第 h 層の $\frac{\partial E}{\partial S_j^{(h)}}$ は, 第 $(h+1)$ 層の $\frac{\partial E}{\partial S_i^{(h+1)}}$ によって求まる漸

化式の一つである．そのため，中間層の層数に関わらず，出力層から最終層の各素子における $\frac{\partial E}{\partial S_i}$ を求めれば，式に相当する漸化式を出力側から入力側へ向けて順に適用することで，全層の全素子における $\frac{\partial E}{\partial S_i}$ を求めることができる．

このように，誤差逆伝搬法では，出力層から入力層へ $\frac{\partial E}{\partial S_i}$ の値が逆伝搬している．

第 5 章ニューラルネットワークを用いた出穂期の予測モデルの構築

出穂日の予測による，最適な登熟環境を導く移植日の決定を行うため，ニューラルネットワーク (NN) による出穂日予測モデルを作成する．

予測モデルの対象とする品種は，星野村において主に育てられている，夢つくし，ミネアサヒ，つくしろまん，ヒノヒカリの 4 品種とする．

また，1，2 における NN の作成に用いた移植日と出穂日のデータは，福岡県農業総合試験場内本場 (1988～1992，1993，1995～2007)，豊前分場 (1985～1990，1993，1997～2001，2002)，筑後分場 (1993，2007) と本研究の対象フィールドである星野村 (2007) において計測されたものである．気温のデータは，星野村については調査水田の計測値，試験場については最寄りの気象台の計測値を使用する．日長のデータは天文日長を用い，星野村の日長は山間地である事を考慮する．

章で紹介した堀江らのモデル (1986) における概念を参考とし，移植日から出穂日を予測するための要素として，日長と気温を提案する．しかし，日長，気温のデータは膨大であり，日平均気温などのデータをそのまま NN の入力しては，入力層の素子数が大きくなりすぎてしまい，実用的ではなくなる．そこで平均気温・平均日長を入力層の素子として NN を作成する．

① NN の作成

日長・気温のデータを簡素化するため，移植日から出穂日までの日平均気温，日長時間から平均気温および平均日長を求める．この平均気温・平均日長と移植日を入力，出穂日を出力とし，中間層は素子数 5 の 1 層とする，3-5-1 階層型の

NNを作成する．NNで取り扱えるよう，移植日，出穂日は日付を数値化するため，4月1日からの日数を365で割った値を用いる．

なお，作成するNNは，決定的アルゴリズムの素子によるフィードフォワード型を用い，学習則には誤差逆伝搬法を用いる．学習回数は10万回，学習係数は0.6，慣性係数は0.8に設定する．

② 結果と考察

表1に教師データの学習結果を示す．平均誤差は，極早生，早生，中生の順で，すなわち，日長感応性が高い品種ほど大きくなった．これは，今回作成したモデルが，日長の影響を表す指標として，移植日から出穂日までの平均値という非常に単純化したものを用いていることが原因の一つとして推察される．しかしながら，平均誤差は最大で2日程度であり，教師データに対しては比較的高い推定精度が確認できた．

品 種	ミネアサヒ	夢つくし	つくしろまん	ヒノヒカリ
早 晩 性	極 早 生	極 早 生	早 生	中 生
教 師 デ ー タ 数	11	9	14	15
平 均 誤 差 (日)	0.6	0.8	1.2	1.9
最 大 誤 差 (日)	1.5	1.6	2.7	4.4

表 5-1 教師データの学習結果




図 5-1 教師データの学習結果

第 6 章 出穂期の予測モデルによる移植日決定の結果， 学習外データに対する精度に対する考察

6-1 出穂期の予測モデルによる移植日決定と考察

4 章にて作成された NN を用いて，移植日予測を行う．
まず，4-1 の平均気温・平均日長を用いた NN によって，移植
日の決定を行う．

NN を用いて，2007 年度において，移植日から出穂日を求
め，次にその後 20 日間（登熟前期）の平均気温を計算した．
なお，作成モデルを用いた出穂日の予測に際しては，出穂日
が未知であるため，入力の平均気温と平均日長が定まらない．
そこで計算時には，出穂日の初期値を与え，その後，出力さ
れた出穂日との比較を行い，十分に初期値が出力値に近づく
まで出穂日の値の更新を繰り返した．また，7 月下旬～10 月
月上旬までの気温のデータについては，研究対象フィールドの
星野村で実際に計測したもの，他の期間については最寄りの
気象台の計測値を補正した値を用いた．図に各移植日に対す
る登熟前期の平均気温を示す．




図 6-1 出穂予測モデルによる
移植日からの出穂予測

各品種ともに，8 月二半旬に出穂日が予測された時の 26.5℃ 付近にピークがあり，その時の移植日は中生品種のヒノヒカリが極早生品種に比べ一ヶ月程早くなった．これは，極早生品種と中生品種の栄養成長期間の違いからも妥当な結果と判断される．一方，早生品種のつくしろまんの移植日のピークが極早生品種より遅くなっているのは，モデル作成に使用したデータに早い移植日のものが含まれていなかったため，予測精度の低下を招いたと考えられる

また，稲の登熟における食味の最適温度は 25~26℃ 付近であることを元に上の表から最適な移植日を推定すると，①4/月下旬から5月上旬，もしくは②5月下旬から6月上旬のどちらかであると考えられる．①，②のどちらが移植日候補として適切かを判断する温度条件としては，活着と分けつの限界温度が考えられる．活着・分けつの温度条件は表のようになる．4~6 月における日平均気温・最低気温は図のようになるので②の 5 月下旬から 6 月上旬付近が移植の最適時期である，と判断ができる．

表 6-1 活着・分けつの温度条件

	活着	分けつ
限界気温	12℃	15~16℃

以上から，移植日決定における NN の使用には精度改善が必要であり，そのためには多様な条件下のデータを用いたモデルの構築とより適切な入力素子の解明が必要となる．

6-2 学習外データに対する予測精度と考察

ニューラルネットワークが，日長時間と気温の環境条件と稲の移植－出穂間の間にある関係性を十分に学習できており，未知のデータに対して十分に信頼できる値を出力するかを調べる．今回は4品種の中からつくしろまんを学習外のデータに対し，高い予測精度を持つか調べる．調査手順は以下のように行う．

- ① まず，つくしろまんの移植日－出穂日の組み合わせデータ14組のうち1番目のデータを抜き取り，それを学習データから外す．
- ② 残りのデータ13組によってニューラルネットワークの学習を行う．
- ③ 学習外として取り出したデータの移植日をニューラルネットワークに入力し，予測出穂日を求める．予測日と実際の出穂日の誤差を求める．
- ④ 以下の手順を残る2番から14番までの全ての組み合わせに対して行う．

これにより求めた誤差の結果を以下に示す．




図 6-2 NN1 による学習外データへの誤差




図 6-3 NN2 による学習外データへの誤差

以上から，図 6-2 から NN1 はデータ番号 1～4 において大きく誤差を出した．また，図 6-3 から NN2 は 1～4 番に加えて，5～14 においても NN1 に対して大きな誤差を出した．1～4 番は山間地のデータであり，また 5～14 番は平野部のデータであることを考慮すると，NN1，NN2 が，山間部のデータが 4 組しかなく，図 6-4 に示される山間地での日長時間のばらつき(図 6-4 において一番上の線グラフが平野部，他 3 つは山間地の日長時間)のため学習できていない事，また，NN2 は入力素子とした，近似した 2 次関数の係数はデータの識別には十分でも，データ同士の関係性を学習するには不十分であった．




図 6-4 日長時間

第 7 章 結論

以上のように本研究は，ニューラルネットワークに稲とその生育環境の関係性を学習させて移植日から出穂日を予測し，その確からしさを測定した．その結果を以下に示す．

(1)ニューラルネットワークは学習データに対して NN1 は約 0.5 日，NN2 は約 0.2 日の誤差を出す．

(2)ニューラルネットワークは学習外データでは山間地の日長がばらつきがあり，データ不足のため，山間地での出穂予測は誤差が大きくなる．

(3)NN2 に導入した，近似した 2 次関数の係数はデータ識別には用いられるが，データを基に出穂予測をできるだけの関係性の学習には不十分である．

そのため，今後は，山間地の生育環境と移植日，出穂日に関してより多くのデータを収集し，出穂日予測のための入力要素に関して モデル，稲の性質も踏まえ，更なる検討，違う視点からの登熟環境の最適化へのアプローチを行う必要がある．

謝 辞

本論文の作成にあたり，ご指導，ご協力を承りました九州大学大学院生物資源環境学科生産環境科学部門生産環境情報学講座の森 健教授，平井 康丸准教授に深く感謝し，厚くお礼を申し上げます．

また，多方面にわたり広くご意見，ご協力をいただいた生産環境情報学研究室の博士の特別研究員 Bui Quoc Lap 氏，博士課程の濱上 邦彦氏，富田 景子氏，Nguyen Van Tuan 氏，修士課程の柿崎 新之助氏，木佐貫 順子氏，Vu Chi Cong 氏，システム工学分野，研究室の同期のメンバー，すべての皆様に深く感謝いたします．

最後にいつも影ながら協力，激励してくださった家族に心より感謝の意をささげて結びとさせていただきます．

2008 年 3 月

横山 剛 宗

参考文献

- 西山岩男(1985), イネの冷害生理学, 北海道大学図書刊行会
- 菅洋(1979), 作物の発育生理, 養賢堂
- 星川清親(1975), イネの生長, 農山漁村文化協会
- 石田良平・村瀬治比古・小山修平(1997), 遺伝的アルゴリズムの基礎と応用, 森北出版株式会社
- 菅沼研究室(静岡理科大学総合情報学部),
http://www.sist.ac.jp/~suganuma/kougi/other_lecture/SE/net/net.htm
- 村山登・吉田よし子・長谷川周一・吉永一博(1986), 稲作科学の基礎, 博友社
- 田村良文(1989), 発育ステージの予測モデルとその実用化—とくにノンパラメトリック法を中心に—, 農業技術 44(9), 397-400
- 堀江武・中川博視(1990), イネの発育過程のモデル化と予測に関する研究, 日本作物学会紀事 第59号, 687-695