

家畜飼養管理システムへのニューラルネットワーク
の適用に関する研究(I)

－ 肥育豚の成長予測－

佐竹隆顕・澤村 篤・立花文夫・古谷立美

A Study on Application of Neural Network to
Livestock Management System (I)

－ Growth Prediction of Swine－

Takaaki SATAKE, Atsushi SAWAMURA
Fumio TACHIBANA and Tatsumi FURUYA

農業施設 第24巻第4号(通巻60号)別刷

1994年3月

Reprinted from

The Journal of the Society of Agricultural Structures, Japan
Vol. 24, No. 4 (Ser. No. 60) March, 1994

家畜飼養管理システムへのニューラルネットワーク の適用に関する研究(I)

—肥育豚の成長予測—

佐竹隆顕*・澤村 篤**・立花文夫***・古谷立美****

- * 筑波大学農林工学系, 〒305 つくば市
- ** 生研機構基礎技術研究部, 〒331 大宮市
- *** 全農飼料畜産中央研究所, 〒300-33 つくば市
- **** 新情報処理開発機構, 〒305 つくば市

要 旨

ニューラルネットワークを援用した家畜飼養管理支援システム構築のための基礎的知見を得ることを目的として、従来から畜産技術者の専門的知識に基づいて予測が行われている肥育豚の仕上り日令に対し、成長予測因子のパターンベクトルをもとに3層のBPニューラルネットワークによる予測を試みる一方、線形重回帰モデルによる予測結果と比較検討を行った。

研究の端緒として、系統、性、生時体重、満8週令までの摂取可消化エネルギーおよび畜舎の舎内平均気温など7つの予測因子を選択してニューラルネットワークによる成長予測シミュレーションを行った結果、精度 $\pm 7.5 \sim \pm 17.5$ 日において仕上り日令に対し約61~96%の見掛けの予測正答率を得た。また線形重回帰モデルによる予測結果に対し、ニューラルネットワークモデルの同正答率は1~11%程度高い値が得られ、その優位性が認められた。

キーワード：飼養管理，肥育豚，成長予測，仕上り日令，ニューラルネットワークモデル，線形重回帰モデル

I. 緒 言

近年わが国では嗜好の多様化にともない、豚肉や鳥肉をはじめとする肉類を大量に消費する形態に食生活が移行してきている。この対応策の一つとして畜産業界では昭和45年頃から豚の大型品種が導入され、肉豚はその三元交雑種が主流になるとともに、出荷日数の短縮や肉量の増加などが計られている。

一般に豚の発育は、離乳期と性成熟期に変曲点をもつシグモイド曲線を描き、肉豚の屠殺・出荷は第2次変曲点にさしかかる時期に行われている。また肉豚は一般的に180日で108kgに達する速度で発育すると言われ

ているが、季節、性、系統、飼養条件などに左右される一方、個体差も大きい(青木ら, 1983; 野口, 1987)。肉豚において、仕上り日令(生体重が100kgに達するまでの所要日数)は出荷時期の見積りや豚房の入替えなどの指標の一つとして重要なものであり、実用上有効な精度でこの日令の予測が可能となれば、飼養管理上大変有効と考えられる。

生物体の成長予測において基礎的知見となる成長モデルに関する研究には、ラット、牛、豚などを対象とした研究(Bridgesら, 1986)および多年性植物を対象とした研究(Smithら, 1983)があり、時間や日令などを説明変数とした2次回帰モデルや指数モデルが検討されてい

る。また、豚を対象としエジンバラモデルと称され、摂取可消化エネルギー、生時体重、性、豚房の床タイプ、飼養密度およびその他の飼養条件をもとに、生体重がほぼ20 kgよりおおむね90 kgに達するまでの肥育所要日数や飼料コストなどを算出するシミュレーションモデルも提案されている(Whittemore, 1980)。しかし、これらのモデルは多様な説明変数を採用していないことや予測精度が明らかにされていないことなどにより、これらのモデルを用い直ちに仕上り日令を予測することは実用上困難な点が認められる。このため畜産業界においては仕上り日令の予測を目的とした新技術の確立が望まれている。

一方、ニューラルネットワーク(以下NNと略す)は産業の各分野において、パターン情報処理の分野を中心にその実用性が着目され、応用に関する基礎研究が行われている(例えば、Furuyaら, 1990; Dengら, 1990; 佐竹ら, 1992; 中野ら, 1992; 池田ら, 1993)。

本研究においては、豚、牛、鶏などの家畜飼養管理にAI技術の中で学習能力および推論・判断能力が高いとされるNNを援用し、従来から畜産技術者の専門的知識により予測が行われていた肥育豚の仕上り日令に対し、系統、性、生時体重、舎内気温などをはじめとした成長予測因子をもとにNNによる予測を試みる一方、線形重回帰モデルによる予測結果と比較検討を行った。

II. 実験方法

1. 供試豚および成長予測因子の選定

本研究に供試した豚は全農飼料畜産中央研究所において1991年8月5日から同年12月23日までに生まれた208頭であり、内訳は去勢雄117頭、雌91頭である。系統としてはランドレース、大ヨークシャー、デュロック、ハンプシャーの4系統を交配した8種の交雑種である。これらの肥育豚を生後3~4週令で離乳させるとともに、分娩豚房より同研究所の第1、第3、第4および第5の4つの豚舎の子豚豚房および肥育豚房に移送し、以後単位質量当たりのカロリーや配合成分などが種々異なる飼料の不断給餌により、生体重がおおむね100 kgに到達するまで飼育した。飼育形態は群飼である。供試豚の成長の様子を個体コード1901の豚(ランドレース、大ヨークシャーおよびデュロックの交雑種、雌)を例として図1に示す。

一般に肥育豚の成長過程はその生体重に着目して初期増加、恒率増加および減率増加期間の3つのステージに分けることができる。肥育豚は体重の初期増加期間内

で母乳より離乳した後、順次人工乳および養豚用配合飼




図1 肥育豚の成長特性曲線の一例

料により飼育されるが、母乳より離乳後のおおむね生後4~7週令の間で体重の恒率増加期間に転じ、さらに生体重が100 kgに達する頃には徐々に増体速度が低下してくる。恒率増加や減率増加の各成長ステージへの移行時期や恒率増加成長曲線の勾配は各個体要因や飼育要因により微妙に異なっており、これが仕上り日令の予測を困難にしている点となっている。

一方、仕上り日令は系統、性、生時体重、摂取エネルギー、飼育環境(気温、湿度、風速など)およびその他の要因の影響を受けるとされている。仕上り日令の予測は、飼養管理上飼育のできるだけ早期の段階でそのめどがたつことが望ましいが、仕上り日令の予測に関する研究の端緒として、本研究においては发育ステージIの初期増加期間が終了した段階で仕上り日令の予測を試みることにした。成長予測因子としては系統、性、生時体重、満8週令体重、満3週令から満8週令までの体重の増分、満8週令までに摂取した飼料の累積可消化エネルギーおよび満4週令から満8週令までを過ごした豚舎の舎内(当該肥育豚房およびその周辺)平均気温を採用することとした。

2. 成長予測因子データの集録および解析

成長予測因子データの集録および解析を目的とした飼育データのフローを図2に示す。

成長予測因子の内、生体重に関するデータについては、208頭の供試豚の誕生から仕上り(おおむね生体重100 kg)まで1週間ごとにロードセルを下部に設置した体重測定ケージを用いて生体重を計測し、生時体重、満8週令体重および満3週令から満8週令までの体重の増分の各予測因子データを得た。

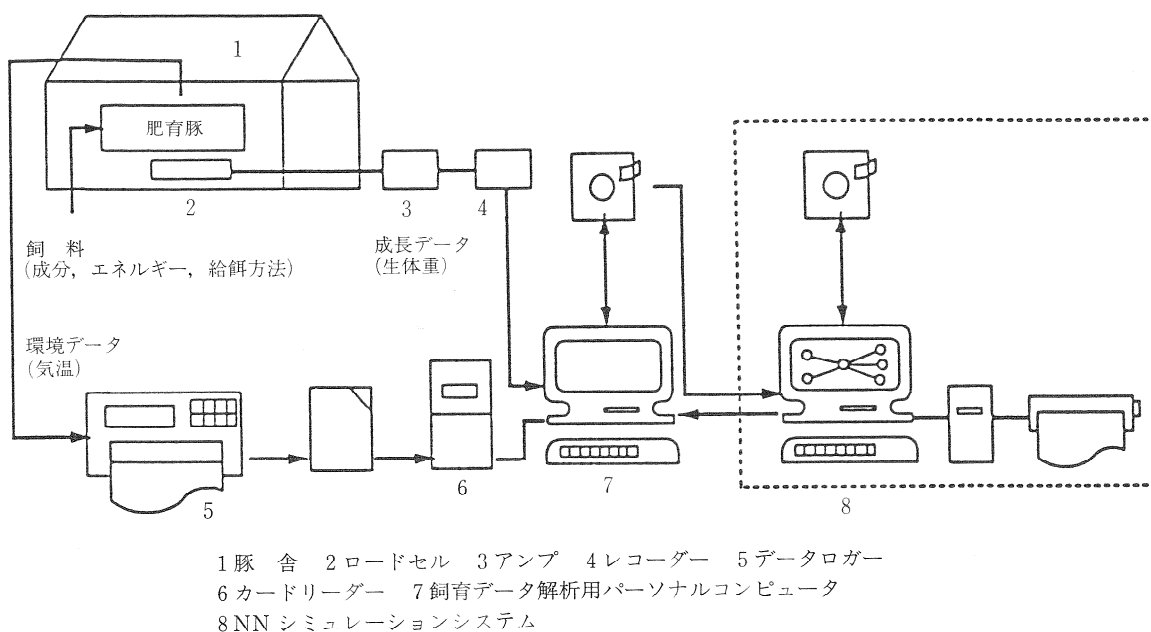


図2 NNによる成長予測シミュレーションのためのデータフロー

また、各豚房に給餌した飼料の供給量およびその残量を基に、群飼いたした各供試豚が満8週令までに摂取した累積可消化エネルギーを算出した。同じ豚房で飼育した各供試豚がそれぞれ摂取した各個体ごとの同データの直接的な把握は困難であるため、次式により摂取可消化エネルギー DE を算出した。

$$DE = \frac{1}{3} \sum_i TDE_i \left(\frac{1}{N_P} + \frac{2 \Delta W_i}{\Delta T W_i} \right) \quad (1)$$

ここで、TDE_iは同一豚房内の全供試豚がi週令で摂取した可消化エネルギー(Mcal)、N_Pは同一豚房内の供試豚頭数、ΔW_iは当該供試豚のi週令の体重の増分(kg)、ΔTW_iは同一豚房内全供試豚のi週令の体重増分(kg)。

一方、CC熱電対を豚房の床面からおおむね150cmの高さに各豚舎ごとに6~9ヶ所配置するとともに、別棟の計測室に設置したデータロガー(横河電機, HR1300)に導き、豚舎内の気温の計測を行った。一端、データロガーに収録した気温データをICカード(512kバイト)およびカードリーダー(横河電機, cm-2)を介して飼育データ解析用のパーソナルコンピュータ(NEC, PC9801RA)に入力し、体重、およびそれぞれ1週間毎の飼料摂取量、可消化タンパク摂取量、リジン摂取量といった他の飼育データとともにデータ収録ならびに解析を行った。供試豚を飼育した豚舎の内、第1豚舎(10m×40m)は南北に長い南北棟であり、一方第5豚舎

(8m×66m)は東西棟であるため、両豚舎のほぼ中央でそれぞれ大きく豚房を2分し、その区分ごとに配置した各熱電対の2時間ごとの出力をもとに舎内平均気温を求める一方、当該区分の豚房において飼育した供試豚の飼育環境(気温)データとした。第3豚舎(10m×15m)および第4豚舎(9m×18m)は、豚舎に配置された6ヶの熱電対の出力をそれぞれ平均化し、当該豚舎にて飼育した供試豚の飼育気温データとした。

以上の方法により得られた各供試豚の成長予測因子データの平均値および標準偏差などの基本統計量を表1に示す。なお同表中には各供試豚の生育記録に基づいて内挿法により求めた仕上り日令に関する統計量も合わせて示した。

表1 供試豚の仕上り日令と成長予測因子データの基本統計量

	仕上り日令(d)	生時体重(kg)	満8週令体重(kg)	満3~8週令体重増分(kg)	満8週令まで摂取DE(Mcal)	満4~8週令舎内平均気温(°C)
平均	157.8	1.36	18.77	12.91	73.99	16.9
標準偏差	15.5	0.27	4.18	3.47	19.46	4.7
最小	128	0.63	8.85	4.90	31.13	10.1
最大	207	1.88	28.33	21.45	119.09	24.5

※1) DE: 可消化エネルギー
2) 成長予測因子としては上記以外に a)系統 b)性別も選択している
3) 供試豚: 208頭

表 1 に示すように、まとめた 5 つの成長予測因子はいずれもデータのばらつきが大きく、個体条件や飼育気温条件は多様である。さらに、供試豚の仕上り日令は成長の一番速いもので 128 日、これに対して一番遅いもので 207 日であり、平均して 157.8 日で生体重 100 kg に達している。仕上り日令の分布の幅は 79 日であり、成長予測の困難さの一端がうかがえる。

3. ニューラルネットワークモデル

成長予測を目的としたニューラルネットワークとしては、優れたパターン分類能力をもつとされる階層型ニューラルネットワークを用いた。また、成長予測シミュレーションを実施するにあたり、はじめに同ニューラルネットワークのアーキテクチャの決定を目的としたシミュレーションを準備的に行った。

すなわち入力層のユニット数(系統、性、生時体重といった肥育豚の成長予測因子の数)および中間層の数を種々変えるとともに、3 万回程度の学習をニューラルネットワークに課し、シミュレーションを行った。それぞれの学習過程において、成長予測ニューラルネットワークの出力の教師信号(実際の仕上り日令)に対する適合性の指標である RMS 値(ニューラルネットワークの出力と教師信号との誤差の 2 乗平均平方根値)をモニターすることにより、最終的に階層型成長予測ニューラルネットワークのアーキテクチャを決定した。

図 3 に成長予測に適用した 3 層 NN モデル(7-n-1)を示す。同モデルの入力層は 7 個のユニット、出力層は 1 個のユニットより構成するとともに、7 つの




図 3 成長予測 NN モデル(7-n-1)

入力ユニットには供試豚の系統、性別、生時体重、満 8 週令体重、満 3 週令から満 8 週令までの体重の増分、満 8 週令までに摂取した飼料の可消化エネルギーおよび満 4 週令から満 8 週令までを過ごした豚舎の舎内平均気温を与え、1 つの出力ユニットは仕上り日令に対応させた。中間および出力層の各ユニットの入出力関数としてはシグモイド関数を用いた。

また実際の仕上り日令とニューラルネットワークが出力する予測仕上り日令の差を最小とするように、バックプロパゲーション(以下 BP と略す)学習法(Rumelhart ら, 1986)により同モデルの学習を行った。

4. ニューラルネットワークによる成長予測シミュレーション

飼育データのフローとともに図 2 に示す NN シミュレーションシステムのパーソナルコンピュータ(NEC PC-9801ES, 数値データプロセッサおよび EMS ボード搭載)上で BP ネットワークを走らせ、成長予測シミュレーションを行った。シミュレーションは供試豚の系統、性、生時体重といった前述の成長予測因子をもとに、当該供試豚が生体重 100 kg に達する仕上り日令を予測するものである。すなわち各成長予測因子データの最小値を 0、最大値を 1 として 0~1 の間に正規化した供試豚の系統、性、生時体重およびその他の成長予測因子のパターンベクトルをそれぞれネットワークに入力する一方、教師信号として、同じく 0~1 の間に正規化した当該供試豚の仕上り日令を併せて入力し、ニューラルネットワークに学習させるという方法を用いた。これにより、学習が終了したニューラルネットワークに対し、ある系統、性、生時体重、満 8 週令体重、満 3 週令から満 8 週令までの体重の増分、満 8 週令までに摂取した飼料の可消化エネルギーおよび満 4 週令から満 8 週令までを過ごした豚舎の舎内平均気温などの正規化した値を入力すると、信号が中間ユニットを経由して出力ユニットに伝わり、予測仕上り日令が出力される。

なお階層型ニューラルネットワーク中間層のユニット数および BP 学習サイクル数はニューラルネットワークの出力結果に影響を与えることが予想されたため、中間層ユニット数を 1~15 個および学習サイクル数を 1000~25 万回の間で種々変えてシミュレーションを行った。各シミュレーションは学習係数を $\eta=0.9$ および慣性項係数を $\alpha=0.6$ に設定して行った。

シミュレーションの結果、得られた予測仕上り日令と実際の仕上り日令の残差(仕上り日令-予測仕上り日令)について、クラス幅を 5 日とした度数分布を求め

た。度数分布は残差が0, すなわち仕上り日令に予測仕上り日令が一致する場合を中心として, まずクラス境界値を-2.5~+2.5日(クラス幅5日)に設定した後, 順次他の境界値を設定し, 各クラスに含まれる残差の分布を求めた。次に各クラスに含まれる残差度数をもとに, 予測精度±2.5, ±7.5, ±12.5および+17.5日における見掛けの予測正答率Pを次式により求めた。

$$P = (F \pm \alpha / N) \times 100 \quad (\%) \quad (2)$$

ここで, $F \pm \alpha$ はクラス境界 $-\alpha \sim +\alpha$ 日(予測精度± α 日)に含まれるクラスの残差度数, N は全供試豚頭数。

5. 線形重回帰モデルによる成長予測シミュレーション

先のニューラルネットの学習に用いた208頭の供試豚の成長予測因子データと同じデータをもとに, 線形重回帰モデルによる成長予測の検討を行った。NNによる予測結果との比較検討を行う観点より, 各成長予測因子の仕上り日令への寄与を考慮する変数増減法ではなく, 説明変数として先の系統, 性, 生時体重, 満8週令体重など7つの成長予測因子をすべて取り入れる一方, 目的変数は生体重100kgの仕上り日令とした。得られたモデルの説明変数に208頭の供試豚の成長予測因子データを代入し予測仕上り日令を求めるとともに, 予測結果をNNによる場合と同様にとりまとめ, 各予測精度における見掛けの予測正答率を求めた。

III. 実験結果および考察

1. 線形重回帰モデルによる仕上り日令の予測

従来から経験的に肥育豚の成長速度に影響があると考えられている系統, 性, 生時体重に加え, 満8週令体重, 満3週令から満8週令までの体重増分, 満8週令までに摂取した飼料の可消化エネルギーおよび満4週令から満8週令までを過ごした豚舎の舎内平均気温など7種のデータを説明変数とし, 生体重100kgの仕上り日令を目的変数とする重回帰分析を行い, 次式の線形重回帰モデルを得た。

$$Y = 178.78 + 2.66 X_1 + 8.56 X_2 - 12.32 X_3 - 2.46 X_4 + 0.91 X_5 - 0.01 X_6 + 0.51 X_7 \quad (3)$$

(決定係数: 0.516)

ここで, Y は仕上り日令(d), X_1 は系統として8交雑種に割付けた1~8の整数値(-), X_2 は性として雌雄に割付けた整数値1または2(-), X_3 は生時体重(kg), X_4 は満8週令体重(kg), X_5 は満3週令から満8週令までの体重増分(kg), X_6 は満8週令までの摂取可消化エネルギー(Mcal), X_7 は満4週令から満8週令までを過ごした豚舎の舎内平均気温(°C)。

偏重回帰係数のt検定の結果, 変数 $X_1 \sim X_4$ および X_7 の係数は1%の危険率でそれぞれ有意であり, 変数 $X_1 \sim X_4$ および X_7 は仕上り日令の変動を十分説明していると考えられる。一方, 仕上り日令の変動に対する変数 X_5 および X_6 の寄与は統計的には認められなかった。満8週令までの摂取可消化エネルギーについては, 同データが各個体ごとに実際に摂取した値ではなく仮定に基づく計算値であることにも起因していると考えられる。変数増減法によれば有意差の認められないこれら2つの変数を棄却し, モデルを決定することになるが, 2つの変数とも意味から考えてそれなりに仕上り日数の変動に対する寄与があるものとみなし, 最終的に(2)式を採用することとした。

208頭の供試豚の実際の仕上り日令および(2)式の右辺に各供試豚の当該データを代入し求めた予測仕上り日令の散布図を図4に示す。同図に示した2つの仕上り日令の相関を示す重相関係数として0.719が得られた。




図4 線形重回帰モデルによる成長予測結果




図5 予測仕上り日令残差のヒストグラム
 ▨ 線形重回帰モデル
 ▩ NNモデル(7-7-1, 学習サイクル数25万回)

また、重回帰モデルによる予測仕上り日令と実際の仕上り日令の残差について、クラス幅を5日としたヒストグラムを図5に示す。同図から明らかなように、仕上り日令に対して予測仕上り日令が2.5日~7.5日多い場合が全データ中54件(26.0%)と最も多く、次いで予測仕上り日令と仕上り日令の差が2.5日以内の場合が40件(19.2%)である。また、予測精度±2.5, ±7.5, ±12.5および±17.5日における線形重回帰モデルによる見掛けの予測正答率はそれぞれ19.2, 59.1, 80.8および92.8%であった。

2. ニューラルネットワークによる仕上り日令の予測

1) NNによる予測の傾向

NNにより肥育豚の仕上り日令を予測した結果の一例を散布図として図6に示す。同図は208頭の供試豚の成長予測因子データを学習データとし、中間ユニット数を7個としたニューラルネットに入力する一方、25万回の学習を行うことにより得られた予測仕上り日令と実際の仕上り日令の関係を示したものである。




図6 NNによる成長予測結果の一例


図4に示した線形重回帰モデルによる予測結果に比べ、図中に示した仕上り日令と予測仕上り日令の一致を示す直線のより近傍への分布が進み、2つの仕上り日令の間の相関係数として0.826が得られたことより、NNによる仕上り日令の予測精度の向上が認められる。またNNモデルによる予測仕上り日令と実際の仕上り日令の残差について、クラス幅を5日としたヒストグラムを先の図5に示した線形重回帰モデルによる予測結果のヒストグラムと合わせて同図中に示す。予測仕上り日令と仕上り日令の差が2.5日以内の場合が全データ中39件(18.8%), 仕上り日令に対して予測仕上り日令が2.5日~7.5日多い場合が56件(26.9%), 逆に2.5日~7.5日少ない場合が49件(23.6%)である。線形重

回帰モデルによる予測が実際の仕上り日令より全体としてやや遅く見積もられるのに対し、NNモデルによる予測は中間ユニット数や学習サイクル数により異なるものの、予測精度±2.5日を中心に予測の偏りはさほど認められなかった。

2) 仕上り日令の予測に対する学習サイクル数の影響

NNモデルに課す学習サイクル数を25万回まで種々変えて成長予測シミュレーションを行った結果を図7に示す。同図中には線形重回帰モデルによる見掛けの予測正答率も該当する予測精度と同じ種類の線により合わせて示した。

同図から明らかなように、予測精度±2.5日の場合を除き、大方の傾向として学習サイクル数の増加にともない他の予測精度における見掛けの予測正答率は向上し、この傾向は予測精度±7.5日において特に顕著であった。また、おおむね5万回以上の学習をニューラルネットに課すことにより、予測精度±7.5, ±12.5および±17.5日において線形重回帰モデルによる見掛けの予測正答率を2~10%程度上回る結果が得られた。



予測精度(d): ■±2.5, +±7.5, ●±12.5, ▲±17.5
NNモデル(7-7-1), 学習係数 0.9, 慣性項係数 0.6
学習データ数 208, 判定データ数 208


図7 見掛けの予測正答率に対する学習サイクル数の影響

3) 仕上り日令の予測に対する中間層ユニット数の影響

図3のNNモデルの中間層ユニット数を15個まで種々変えて成長予測シミュレーションを行った結果を図8に示す。同図中には図7と同様に線形重回帰モデルによる見掛けの予測正答率も該当する予測精度と同じ種類の線により合わせて示した。

予測精度±7.5日の場合を除き、中間ユニット数の増加にともない全体として見掛けの予測正答率は増減して

いることから、予測正答率に対する中間ユニット数の影響は明らかではなかった。一方、中間ユニット数をおおむね 5 個以上に設定することにより、各予測精度において異なるものの線形重回帰モデルによる見掛けの予測正答率をおおむね 1~11% 程度上回る結果が得られ、肥育豚の仕上り日令予測における線形重回帰モデルに対する NN モデルの優位性が認められた。また、今後の研究の進捗にともない実用上のレベルまで NN モデルの予測精度を高めることができれば飼養管理上有効であるととも、食肉市場の需給動向を考慮しながら得られた予測結果に基づいて舎内気温や飼料成分・給餌方法などを修正しつつ成長速度を制御する家畜飼養管理支援システム構築の一助になるものと考えられる。



予測精度(d) : ■±2.5, +±7.5, ●±12.5, ▲±17.5
 学習サイクル数 5 万回, 学習係数 0.9, 慣性項係数 0.6
 学習データ数 208, 判定データ数 208

図 8 見掛けの予測正答率に対する中間層ユニット数の影響

IV. 摘 要

ニューラルネットワークを援用した家畜飼養管理支援システム構築のための基礎的知見を得ることを目的として、ニューラルネットワークによる肥育豚の仕上り日令の予測を試みた。従来の予測技術としての線形重回帰モデルによる予測結果と比較検討し、以下の知見を得た。

1. ニューラルネットワークモデルとの比較検討を目的として求めた線形重回帰モデルによる見掛けの予測正答率は、予測精度±2.5, ±7.5, ±12.5 および±17.5 日においてそれぞれ 19.2, 59.1, 80.8 および 92.8 %であった。また同モデルによる予測仕上り日令と実際の仕上り日令の間の重相関係数は 0.719 が得られた。

2. 線形重回帰モデルによる予測は実際の仕上り日令より全体としてやや遅く見積られるのに対し、ニューラルネットワークモデルによる予測は予測精度±2.5 日を中心に予測の偏りはさほど認められなかった。
3. おおむね 5 万回以上の学習をニューラルネットワークに課すことにより、予測精度±7.5, ±12.5 および±17.5 日において線形重回帰モデルによる見掛けの予測正答率を 2~10% 程度上回る結果が得られた。
4. 中間ユニット数をおおむね 5 個以上に設定することにより、各予測精度において異なるものの線形重回帰モデルによる見掛けの予測正答率を 1~11% 程度上回る結果が得られ、肥育豚の仕上り日令予測における線形重回帰モデルに対するニューラルネットワークモデルの優位性が認められた。

おわりに、本研究は肥育豚の成長予測にニューラルネットワークを適用した端緒の研究であり、今後は予測精度の一層の向上を目的として通年の飼育データの集録を進める一方、より適切な成長予測因子の抽出を検討する必要がある。さらに仕上り時の肥育豚の肉質評価予測なども含めてシミュレーションを実施し、家畜飼養管理支援システムの構築に向けた基礎データの蓄積を計る必要がある。

なお、本研究を実施するにあたり、筑波大学農林工学系技官橋本光氏およびバイオシステム研究科大学院生月成顕子さんには多くのご協力を頂いた。記して謝意を表する次第である。

引用・参考文献

1. 青木利恵子・野口剛・他(1983) : 子豚の初生体重と 17 週令までの体重の 100 kg 到達日令との関係. 全農飼料畜産中央研究所試験研究報告, 12 : 145-152.
2. Bridges, T. C., Turner, L. W., et al.(1986) : A Mathematical Procedure for Estimating Animal Growth and Body Composition. Transactions of the ASAE, 29 (5) : 1342-1347.
3. Deng, C. and Haykin, S. (1990) : A Multi-layer Neural Network Classifier for Radar Clutter. IJCNN'90 : 241-246.
4. Furuya, T. and Kokubu, A. (1990) : μ BRAIN : A Structured Neural Network for Connectionist Intelligent Systems. ICNN 90 : 428-432.
5. 池田善郎・斉藤義行(1993) : ニューラルネットワークによる農産物の形状判定. 農業機械学会誌, 55 (3) : 59-64.
6. 中野和弘・倉田和彦・他(1992) : 青果物選果システムに関する研究(第1報). 農業施設, 23 (2) : 39-44.
7. 野口剛(1987) : 大型豚の発育成績. 全農飼料畜産中央研究所試験研究報告, 16 : 453-463.

8. Rumelhart, D. E., Hinton, G. E. and Williams, R. J. (1986) : Learning Internal Representations by Error Propagation, Parallel Distributed Processing Volume 1. (Rumelhart, D. E., McClelland, J. L. and the PDP Research Group). MIT Press, Massachusetts, 322-330.
9. Rumelhart, D. E., Hinton, G. E. and Williams, R. J. (1986) : Learning Representations by Back-Propagating Errors. Nature, 323 : 533-536.
10. 佐竹隆顕・古谷立美・他(1992) : 米の品質判定用ニューロプロセッサの開発に関する研究(第1報). 農業機械学会誌, 54(4) : 67-75.
11. Smith, M. E. and Loewer, O. J. (1983) : Mathematical-Logic to Simulate the Growth of Two Perennial Grasses. Transactions of the ASAE, 26(3) : 878-883.
12. Whittemore, T.C. (1980) : The Edinburgh computer model pig. Pig News and Information, 1(4) : 343-346.

A Study on Application of Neural Network to Livestock Management System (I)

—Growth Prediction of Swine—

Takaaki SATAKE*, Atsushi SAWAMURA**
Fumio TACHIBANA*** and Tatsumi FURUYA****

* Institute of Agricultural and Forest Engineering, University of Tsukuba, Tsukuba 305

** Fundamental Technology Department, Bio-oriented Technology Research Advancement Institution, Omiya 331

*** Central Research Institute for Feed and Livestock, Zen-Noh, Tsukuba 300-33

**** Real World Computing Partnership, Tsukuba 305

Summary

In order to obtain basic information for the construction of a livestock management support system using neural network, a simulation of growth prediction of bred swine was conducted using 3 layered back-propagation network. In addition to this, a simulation of growth prediction using linear multiple regression model was also carried out to compare with the result of the simulation using neural network model. As a first step of the study, seven growth prediction factors, such as genealogy, sex, birth weight, intake of digestive energy, average house temperature and others were selected, and the simulation of growth prediction using neural network was carried out by changing the number of hidden units and learning cycles of the network.

As the results of these simulations, the percentage of apparent prediction level of neural network model was about 1~11% higher than that of linear multiple regression model, and it was clarified that the use of neural network was effective for growth prediction of swine.

Keywords : breeding management, swine, growth prediction, finish daily age, neural network model, linear multiple regression model