貯蔵プロセスの最適化のための知能的制御シミュレーション

森本哲夫・Wahyu PURWANTO・橋本 康

愛媛大学農学部 790 松山市樽味

Intelligent Control Simulation for Optimization of Storage Process

Tetsuo MORIMOTO, Wahyu PURWANTO, and Yasushi HASHIMOTO

Dept. of Biomechanical Systems, Ehime University, Tarumi, Matsuyama 790, Japan

Summary

The present work attempted to apply an intelligent control technique including neural networks and genetic algorithms to the optimization of fruit storage process. In the method, water loss of a fruit as affected by relative humidity was first identified using neural networks, and then the optimal setpoints of relative humidity which minimize the objective functions were searched for through simulation of the identified model. Two sorts of objective functions were considered. One is the sum of water loss and the degree of disease of a fruit. The other is the error between the desired values and the current values of water loss. Both are minimization problems. A three layer neural network was effective for building the dynamic model of the water loss of a fruit to relative humidity. A genetic algorithm with high crossover and mutation rates allowed the optimal setpoints of relative humidity to be quickly sought from simulation of the identified model. Thus, a new intelligent control technique combining with neural networks and genetic algorithms was shown to be effective for the optimization of fruit storage process.

はじめに

最近、栽培プロセスだけでなく貯蔵プロセスをも包めたトータルプロダクションシステムが注目されている^{1,2)}。特に果樹(及び果菜)類では最終的な品質が貯蔵プロセスによって決定されるのでそこでの環境制御は重要となる。一般に貯蔵プロセスは栽培プロセスよりも環境条件の影響を強く受け、また制御対象が庫内に限定されているので環境制御の効果は大きいと考えられる。特にリンゴのような長期的な貯蔵が可能である果実はこれが言える^{1,3)}。

前報ではニューラルネットワークおよび遺伝的アルゴリズムを利用した新しい知能的制御法を提案し柑橘類の貯蔵庫の換気制御を試みた²⁾。本報では、同様な方法論で、低温貯蔵(2°C)におけるリンゴ果実の蒸発散による水損失を最適にする湿度制御問題に拡張し、シミュレーションから本制御法の有効性を検討した。

1994年12月27日受理

貯蔵プロセスの最適化

1. 最適化問題

貯蔵において新鮮さを維持することは非常に重要である。このためには果実の蒸発散による水損失をできるだけ抑制する必要がある³⁾。果実の水損失に大きな影響を与えるのは主に庫内の湿度と温度であり、これらの効果的な制御が品質の向上や維持につながると考えられる。ここでは湿度に注目し2つの最適化問題を考えた。なお実験に用いた果実はリンゴ(Janagold)である。実験は低温貯蔵室(温度 2°C)で行い、果実の水損失は重量変化から求めた¹⁾。

(1) 最適化問題 I

果実の水損失を抑制するには湿度が高い方がよい。しかし高すぎるとカビや細菌類に起因する病気が発生しやすくなる。このため病気の発生を抑制するには湿度を下げた方が望ましい。そこで、湿度操作が相反する果実の水損失と病気の発生度合いを目的関数として、それが最小となる4段階の相対湿度を求める最適化問題を考えた。この場合の目的関数は次のように与えられる。

$$F_1(h) = \sum_k (\alpha \cdot W_h(k) + \beta \cdot D_h(k)) \quad \dots (1)$$

ここで $W_h(k)$, $D_h(k)$ は湿度操作 h に対する水損失及び病気の発生度合いの時系列であり、ここでは $0 \leq W_h(k)$, $D_h(k) \leq 1$ (k : 日数) である。 α と β は重みであり、 $0 \leq \alpha, \beta \leq 1$ とする。

(2) 最適化問題 II

果実の水損失が希望通りに制御できれば出荷調整などが可能となる。水損失を希望通りに制御するのは目標値に追従させることで実現できる。そこで、目標値との誤差を目的関数とし、それが最小となる6段階の相対湿度を求める最適化問題を考えた。この場合の目的関数は次のように与えられる。

$$F_2(h) = \sum_k (W_h(k) - W_{h,ref}(k))^2 \quad \dots (2)$$

ただし $W_{h,ref}(k)$ は水損失の目標値となる関数でありそれは次のような直線式である。

$$W_{h,ref}(k) = c_1 \cdot k \quad (c_1: \text{定数}, k: \text{日数}) \quad \dots (3)$$

2. 知能的制御法

さて上記の最適化問題を如何に解くかは問題であるが、本報では前報²⁾で提案したニューラルネットワークと遺伝的アルゴリズムを組み合わせた知能的制御法を用いる。Fig. 1 はその制御法

Fig. 1 Block diagram of a control system for optimization of fruit storage system

のブロック線図である。まずニューラルネットワークによって環境変動(相対湿度)に対する果実の応答(水損失)を同定してモデルを構築し、次にそのモデルのシミュレーションから目的関数((1)または(2))を最小にする最適な環境条件を遺伝的アルゴリズムを用いて試行錯誤的に探索する。シミュレーションから膨大な試行が現れるがその中から効率的に最適値を選択しようとする試みである。この方法論は人間が過去の経験(学習による精神的なモデルの構築)から最良と思われる戦略を選び出す(最適値の探索)方法と同様である。

3. ニューラルネットワークによる同定法

同定は2入力(相対湿度と日数)－1出力(果実の水損失)動的システムを想定した。同定はFig. 1の右側に示すような3層のニューラルネットワークで行った。入力層には2つの入力と出力の時系列 $\{h(k), \dots, h(k-m), t(k), \dots, t(k-m), W_h(k-1), \dots, W_h(k-m)\}$ を与え、また出力層には現在の出力 $W_h(k)$ を教師信号として与えた($h(k)$:湿度入力, $t(k)$:日数, $W_h(k)$:湿度 h に対する水損失, m :システムパラメータの数)⁴⁾。なお本報ではFig. 2(a)の経日変化をうまく同定するため日数も入力として考え、その与え方による同定精度を調べた。システムパラメータ数 m 及び中間層ニューロン数は試行錯誤的に選んだ。学習法はエラーバックプロパゲーション法であり⁵⁾、学習回数は1万回で打ち切った。

4. 遺伝的アルゴリズムによる最適値の探索法

まず求めるべき決定変数は個体として定義する⁶⁾。本報での個体は、最適化問題Iでは4段階の相対湿度の組み合わせ、また最適化問題IIでは6段階の相対湿度の組み合わせである。

最適化問題I: 個体 = (RH₁, RH₂, RH₃, RH₄)

最適化問題II: 個体 = (RH'₁, RH'₂, RH'₃, RH'₄, RH'₅, RH'₆)

Fig. 2 Daily changes in water loss of a fruit under different humidity conditions.
((1): 40% RH, (2): 95→40→95, (3): 95% RH).

さらに個体中の各相対湿度は7ビットの2進数で表した。これによって最大で123(2進数表示: 1111111)までの値が得られ、 $20 \leq \text{相対湿度} \leq 100\% \text{ RH}$ とした。

まず初期集団として $N=N_0(=6)$ 個の個体をランダムにつくり、次に交叉及び突然変異を行わせる。なお交叉及び突然変異は交叉確率 P_c 及び突然変異確率 P_m に従って行われ、それぞれ N_c 個の個体、 N_m 個の個体をつくる。さらにニューラルネットワークモデルから各個体の適応度を計算し、適応度の高い個体のみを残す(エリート戦略)^{6,7)}。これを繰り返して適応度が最大となる個体を選ぶ。これが求める最適値である。

結果及び考察

1. 果実の水損失 $W_h(k)$ 及び病気の発生度合い $D_h(k)$ と同定結果

目的関数(1), (2)における $W_h(k)$ と $D_h(k)$ の値は同定から得られるモデルから計算される。Fig. 2 は3種の相対湿度に対する果実の水損失の経日変化であり(a)は実測, (b)はシミュレーション結果である。(a)より果実の水損失は相対湿度が高いと少ないが、低いと大きい。また途中で相対湿度を変えると(図中の太い実線)水損失はそれに対応して顕著に変化し相対湿度によって制御可能とわかる。

さて(b)は3層のニューラルネットワークを用いて同定した結果であるが、この場合どのように同定すれば効果的だろうか。Fig. 3 は入力との与え方、特に日数の与え方、の違いによる同定誤差を示したものである。入力として、動的特性を表すため、いずれも相対湿度と水損失の m (ここでは $m=1$) 時点前までの時系列を与えているが、この条件で(A)は日数のない場合、(B)は日数を m 時点前までの時系列とした場合、(C)は日数をその日のみの1個とした場合である。図より(C)の場合が最も推定評差が小さい。これは応答の漸次増大を同定するためには日数の直線的増大を利用した方が有利であり、またこの場合日数を1日のみとした方が実際の水損失応答により近いと考えられる。したがって Fig. 2(b)における同定結果は(C)の場合を採用した。この計算におけるシステムパラメータ数は $m=1$ 、中間層ニューロン数は5である。これらの値はできるだけ短い計算時間と小さな同定誤差を考慮して試行錯誤的に選んだ。したがって入力層ニューロン数は4となる。図より推定された3本の応答は実測値と非常によく似ていることがわ

Fig. 3 Errors under different treatments of day as an input ((A): without day, (B): with time series of day, (C): with only one day).

かる。これにより $W_h(k)$ の値はこのモデルの応答の最終段階での平均値から求められる。

一方、相対湿度と病気の発生度合い(発生頻度%)の関係は長期貯蔵を想定して過去の多くの実験結果から次のような非線形モデル(シグモイド関数)を構築した。

$$D_h(k) = 1 / (1 + e^{-h(k)+92}) \quad \dots (4)$$

病気の発生度合いは約 90% 以上の湿度から増大し約 98% で最大となる。この式は静的モデルであるが、時間的な値は各時間帯での湿度に対する値を用いた。

2. 個体の進化に基づく最適値の探索

遺伝的アルゴリズムによる最適値の探索プロセスは生物の進化と同様である。本研究では最小化問題を解くので、進化は適応度(目的関数)を減少させる方向であり、適応度を最小にさせる個体が求める最適値である。Fig. 4 は最適化問題 I における進化の様子である。交叉確率と突然変異確率が異なる 3 つの場合を示す。横軸は世代交代数、縦軸は適応度(目的関数(1))である。進化の方向は最小化問題なので減る方向であるが、交叉確率と突然変異確率が高い方が最小値へ到達するスピードが速い。しかし交叉確率と突然変異確率を小さくすると最小値へ到達するスピードは遅くなり最小値に到達しない場合も現れた。この状態は局所解に陥ったことを意味している。これより多様性であるほど進化が速く効率的とわかる⁸⁾。

3. 最適制御結果

Fig. 5 は最適制御問題 I, II におけるシミュレーションによる制御結果である。(a) は目的関数(1)を最小にする 4 段階の湿度操作(下図)とそれに対する果実の水損失の応答結果(上図)である。図では目的関数(1)における 2 つの重み α, β が異なる場合を示している。すなわち実線は水損失の重みを小さくしてその抑制を小さくした場合($\alpha=0.4, \beta=1.0$)、点線は水損失の重みを病気発生と同じにした場合($\alpha=1.0, \beta=1.0$)である。図より水損失の抑制を小さくすると(実線)、最適な湿度操作はより低い値を指示している。この指示は目的関数において水損失の抑制よりも病気発生の抑制の方を強くした結果であり、この指示に矛盾はない。このことは本制御法が有効であることを示している。(b) は目的関数(2)を最小とする、すなわち目標値関数に追随するための 6 段階の湿度操作(下図)とそれに対する果実の水損失の応答(上図)である。なお点線は目標値関数であり(3)式において係数 $c_1=0.05$ である。図より水損失は目標値に精度良く制御されているのがわかる。

Fig. 4 Evolution curves of fitness under different crossover and mutation rates.

Fig. 5 Optimal control performances of water loss of a fruit.

結 論

本報では前報で提案した知能的制御法をリンゴ果実の低温貯蔵における水損失の最適化問題に適用しその有効性をシミュレーションから検討した。まず3層のニューラルネットワークを用いて相対湿度に対する水損失の経日変化を同定してモデル化を行ったが、この場合、適度な中間層ニューロン数を選び、日数も入力とすると同定精度が向上した。次にモデルのシミュレーションから最適な環境条件の組み合わせを遺伝的アルゴリズムを用いて求めたが、交叉及び突然変異確率を高くすると進化スピードが増し、局所解に陥ることなく最適値が探索できた。以上より、本制御法は効率的な最適値の探索が可能であり複雑な貯蔵プロセスの最適化に有効と考えられる。今回はシミュレーションからの検討であるが、今後は実際に適用したい。

参 考 文 献

- 1) De Baerdemaeker, J and Y. Hashimoto: Speaking fruit approach to the intelligent control of the storage system. *Proc. of 12th CIGR World Congress*, Vol. 1, 190-197 (1994).
- 2) 森本哲夫・近泉惣次郎・橋本 康: 農産物貯蔵工場の知能的制御. 植物工場学会誌, 6(3), 191-196 (1994).
- 3) 北川博敏: 果実の貯蔵. 冷凍, 64(741), 745-759 (1989).
- 4) Chen, S., S. A. Billings and P. M. Grant: Non-linear system identification using neural network. *International Journal of Control*, 51(6), 1191-1214 (1990).
- 5) Rumelhart, D. E., G. E. Hinton and R. J. Williams: Learning representation by back-propagation error. *Nature*, 323(9), 533-536 (1986).
- 6) Goldberg, D.: Genetic algorithms in search, optimization and machine learning, Addison-Wesley (1989).
- 7) Morimoto, T., T. Takeuchi and Y. Hashimoto: Growth optimization of plant by means of the hybrid system of genetic algorithm and neural network.. *Proc. International Joint Conference on Neural Networks*, Vol. 3, 2979-2982 (1993).
- 8) F. J. アヤラ. 進化のメカニズム. サイエンス, 11月号, 22-37, (1978).