

ニューラルネットにTD-学習を組み込んだ 株式売買意思決定支援システムの構築

大阪教育大学 馬場則夫 BABA Norio

1. はじめに

本研究では、株式売買意思決定支援システムの構築のために、TD-学習[1]を活用することを試みる。

TD-学習は、時系列予測の一手法として、Sutton[1]によって提案された非常に興味深い予測手法である。しかしながら、TD-学習の優れた特徴にもかかわらず、TD-学習の実際問題への応用例はあまり報告されていない。

TD-学習の特徴は、環境の変化に対して機敏に対応できることである。著者らのグループでは、数年来、ニューラルネットを活用した知的株式売買意思決定支援システムの構築に取り組んできたが[2]-[4]、最近、TD-学習を活用することによって株式市場を取り巻く環境の変化に素早く適応できるのではないかと考えるようになった。本研究では、TD-学習をニューラルネットを用いた株式売買意思決定支援システムに活用する方法を示すと共に、最近数年間に渡る計算機シミュレーションを通じて、提案方法の有効性を示す。

2. TD-学習

TD-学習とは、1980年代の後半に Sutton によって提案された Temporal Difference Learning [1] の略称であり、時系列予測の一方法として近年脚光を浴びつつある。本研究では、このTD-学習を株式売買意思決定に活用するが、まずその前に、以下で、TD-学習について簡単な紹介を行おう。

TD-学習においては、従来の教師付き学習法は異なり、連続した予測結果の差を用いて学習を行う。それ故、最終的な結果（教師付き学習における教師信号に相当する。）を待つことなく学習を行うことが可能となる。

紙面の都合により、以下では、具体的なTD-学習のアルゴリズムのみを示そう。観測列 x_1, x_2, \dots, x_m, z と予測列 P_1, P_2, \dots, P_m を考える。

ここで、 x_t ($t=1, \dots, m$) は、時刻 t における観測ベクトルであり、 P_t ($t=1, \dots, m$) は、時刻 t における予測値を表している。ところで、 P_t はウエイトベクトル w と t 時刻における観測ベクトル x_t に依存しているため、次の(1)式のように書くことができる。

$$P_t = P(x_t, w) \quad (1)$$

TD(λ) は、 $0 \leq \lambda \leq 1$ に対して定義されたウエイトベクトル w の変更則を与える：

$$\Delta w_t = \alpha(P_{t+1} - P_t) \sum_{k=1}^t \lambda^{t-k} \nabla_w P_k \quad (2)$$

$\lambda = 0$ と選ぶと、

$$\Delta w_t = \alpha(P_{t+1} - P_t) \nabla_w P_t \quad (3)$$

(3) で与えられる w の変更則は、TD(0)と呼ばれており、過去の予測値の変更は全く考慮しないで最近の変化のみを w の変更利用するものである。

3. TD-学習の導入に関して生じる問題点とその解決策

TD-学習をニューラルネットに組み込むにあたって、幾つかの問題点を解決する必要が生じる。それらを以下に列挙すると、

- 1) P_t のウエイトベクトル w に対する勾配ベクトル $\nabla_w P_t$ の成分の大きさが時刻 t によって大きく変動する。
- 2) P_t は、元々の論文[1]では、スカラーと仮定されていた。複数個の出力ユニットを持つニューラルネットに適用する場合はどうすればよいのか。
- 3) P_t の勾配ベクトル $\nabla_w P_t$ の各成分をどのようにして導くか。

紙面の都合により、これらの問題点の解決法については、当日触れる。

4. 計算機シミュレーション結果

我々のグループでは、TD-学習の有効性を示唆する様々な興味深いシミュレーション結果を得ている。詳細は、当日報告することとし、以下では、その中の幾つかを示す。

Stock	neural network			TD(0) + neural network		
	Profit	Charge for dealing	Profit - Charge	Profit	Charge for dealing	Profit - Charge
1601	0	0.000	0.000	0	0.000	0.000
1801	308	326.850	-18.850	147	60.165	86.835
2001	-238	50.190	-288.190	-149	33.315	-182.315
3402	-101	76.995	-177.995	-35	18.495	-53.495
3407	0	0.000	0.000	0	0.000	0.000
4010	159	129.015	29.985	105	38.565	66.435
4501	0	0.000	0.000	0	0.000	0.000
5001	-27	68.355	-95.355	233	64.455	168.545
5401	0	0.000	0.000	0	0.000	0.000
6702	-778	230.790	-1008.790	602	81.870	520.130
6752	1090	140.250	949.750	1810	129.450	1680.550
6758	4420	489.900	3930.100	4420	489.900	3930.100
7203	1800	265.800	1534.200	1720	156.000	1564.000
8318	710	181.950	528.050	490	185.250	304.750
8604	1110	446.250	663.750	70	57.450	12.550
9101	-202	68.250	-270.250	0	0.000	0.000
Total	8251	2474.595	5776.405	9413	1314.915	8098.085

(Simulation period: March 1993 - February 1994)

(Thousand yen)

謝辞： 計算機シミュレーションに関して協力いただいた元大阪教育大学大学院生の林正明氏に謝意を表したい。

- 文献 1) R. S. Sutton, "Learning to Predict...", Machine Learning, 3, 9-44, 1988.
 2) N. Baba et al, "A Hybrid Algorithm...", Neural Networks, 7, 1253-1265, 1994.
 3) N. Baba et al, "Utilization of NNs & GAs...", Proc. SPIE, 2760, 164-174, 1996.
 4) 馬場他、ニューラルネットの基礎と応用、共立出版、1994.