

気象の予測と研究のためのニューラルネットワーク II*

柳野 健**

1. 学習には難易度がある

前回、ニューラルネットワークは未知の関数関係を近似表現するためのものであることを述べた。今回は、気象予測等への応用の実際について述べる。

われわれの学習体験を想起しよう。自動車教習所で運転を初めて習うとき、なかなかうまくいかない。エンスト、脱輪等して叱られながら上達していく。免許をもらってもまだ一人前ではない。大都市で運転すると周りから叱咤(激励)される。高速道路は冷や汗もの、雨の夕暮れはひどい悪夢である。

学習にはゼロからやるものと、習得したもののバリエーションですむものがある。A社の車で運転に習熟したら、B社の車は味つけが異なるが、その運転は既得の運転技術のバリエーションで円滑にやれる。

このことは、ニューラルネットワークを気象予測等へ応用するとき非常に重要である。例えば、2次関数を学習させてみよう。第1図は、学習の進み具合を示している。最初は白紙の状態から変形合成を模索するので学習に時間がかかる。学習が進んだ頃、この2次関数を突然、上・下あるいは左・右にずらしたとする。当然、大きな誤差が負荷されるが、即時に適応する。関数がずれる変化を、即時に学習できるのである。

前回、学習の仕組みの説明で、バイアスは、シグモイド関数の平行移動に対応すると述べた。バイアスを学習する効率は格段に高い。本稿では、主としてバイアス調整で対応できるような変動の学習をバリエーションと呼ぶ。

このことを考慮すると、ニューラルネットワークを気象予測等に应用するときの基本的な考え方と手順

は、以下のようになる。

十分な期間(1~2年間分)のデータを順次に使って、未知の関数関係を(収束するまで)反復学習(100~200回)させる。6~24時間先の予測ならば、数値予報が予測する大気状態を天気へ翻訳する方式が実用的である。

少し補足する。未知の関数関係を近似表現するためには、全域の情報が必要である。十分な期間のデータを必要とするのは、その意味である。逐次解法で未知の非線形な関数関係へ漸近していくためには、反復学習が必要である。


ところで、数値予報モデルでは、計算機資源の制約から分解能や物理過程等のスペックが決まる。すると、予報精度の大枠も決まる。数値予報モデルは、巨大で精妙なソフトウェアだから、特定の予測を精度の大枠以上に良くしようと無理な調整をすると、全体のバランスを悪くする。そのような訳で、数値予報結果を翻訳する工程を独立に設ける意味がある。それによって予測精度を改善できる理由は、全体への悪影響を気にすることなく、特定地点の特定気象要素毎に、実況に合うようにバイアスを補正したり、閾値を調整したり、数値予報モデルではうまく機能していない重要な物理過程を近似的に含めたりできるからである。手順は、

- ① 十分な期間のデータを使って、未知の関数関係を(収束するまで)反復学習させる。入力因子には、数値予報から関係の深そうな予測値を、真値(教師データ)には、対応する実況値を使う。
- ② 次に、テスト期間のデータを使って予測させ、その予測値と真値から学習させる。このような予測・学習のサイクルをテスト期間にわたって一通り繰り返す。予測誤差を計算させる。
- ③ ②の予測誤差が小さくなるように、入力因子や中間層のニューロン数や学習率を調整しながら、

* Neural Network for Forecast and Research on Meteorological Phenomena Part II.

** Takeshi Yanagino, 気象大学校.

© 1998 日本気象学会



第1図 階層型1-M-1の学習特性. 2次関数を学習途中で, 突然変更する. (a) 2次関数, 突然に鉛直移動する, (b) 学習と, 突然移動後の学習, (c) 2次関数, 突然に水平移動する, (d) 学習と, 突然移動後の学習. 下図の誤差幅は, 50回の実験の標準偏差幅.

①, ②を繰り返し, 最良の設定を見つける.

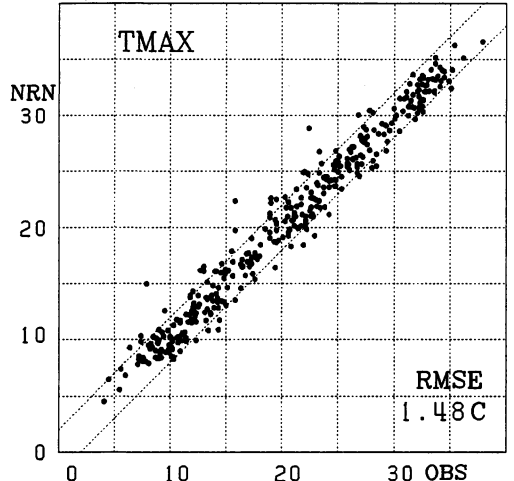
④ 本予測に使う. 予測・学習のサイクルを繰り返す.

まとめると, まず, 十分なデータを用いて, 非線形(線形も含めて)の関数関係を学習させる. すると, それ以後はバリエーションで短期変動に迅速に適応していく.

具体例を示そう. 第2図は東京(大手町)の最高気温をニューラルネットワークで予測させた実例である. 縦軸が予測値, 横軸が対応する実況値である. 斜めの点線の帯は $\pm 2^{\circ}\text{C}$ の誤差範囲である. 1993年度のデータで学習させ(①), 1994年度のテストデータで予測実験した(②)結果である. 誤差は, $\text{RMSE} = 1.48^{\circ}\text{C}$ であった. 第3図は, 同様な予測を行った全国11気象官署平均の, 月別の最高気温予測誤差(RMSE)の推移である. 予測精度はかなり高い. それは, 情報源(数値予報)が相当に良質であることに起因している.

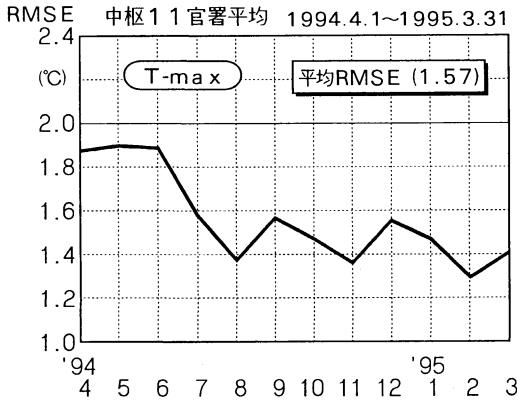
この予測をさらに改善するには, まず, 大きく外れたケースを調べ気象学的な理由を解明することである. もっともな理由があれば, それを説明できるような入力因子を検討し, 取り入れる必要がある.

TOKYO 1994.4.1 - 1995.3.31

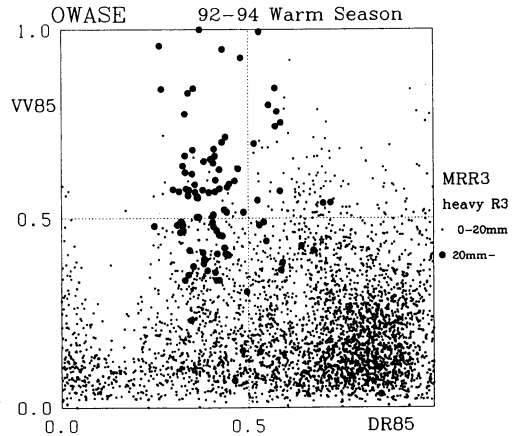


第2図 ニューラルネットワークによる最高気温予測例(東京・大手町). 縦軸が予測, 横軸が実況($^{\circ}\text{C}$). 大きすぎる予測は, フェーン現象の空振りか. 全体の予測精度は高い.

例えば, 「最高気温予測が大きく外れるケースには, フェーン現象の関係したものが多く, 第2図は, フェー



第3図 最高気温予測の1年間の推移。1994年度、11官署の月平均。縦軸は誤差 (RMSE)、横軸は月。



第4図 尾鷲付近の3時間平均雨量。●は、20mm/3h以上の大雨。縦軸は850hPa風向、横軸は同風速。どちらも正規化している。

ン現象による昇温を予測したケースも含んでいる。現在の数値予報は、地上より少し上層ではフェーン現象を良く予測している。だから、数値予報の上層の気温や風等も入力因子に使うと、地上のフェーン現象もかなり予測できる。ところが、フェーン現象を『風下側の昇温を伴う山越え気流』と定義すれば、これはかなり頻繁に起こっている。むしろ、数値予報の上層の気温や風等も入力因子に使うと、山越え気流が地上まで達せず昇温しない空振りが問題となるかもしれない。だから、山越え気流のふるまいを判定する必要がある。それは、気流を感じる地形とフルード数と臨界高度等で特徴づけられるので、それらを入力因子に加えると、判定規準となるはずだから空振りも減るのではないか」といった具合に考察と実験を進め、改善を図る。

2. 顕著現象の予測

学習は事例が多いほどやりやすい。顕著現象は稀にしか起きないため一般に学習は難しい。ただし、大変うまく学習できる幸運な場合もある。

第4図は、1992~1994年暖候期の尾鷲付近の3時間平均雨量を、数値予報の850hPa風向・風速予測値の面上にプロットしたものである。これは大雨確率予測を目的とした調査図なので、20mm/3h以上のものだけを大きな黒丸で表示している。横軸は風向であり、0が北から南へ吹く風、右回りに、0.5が南風、1.0が再び北風である。縦軸は風速で、この期間における風速の最大値を1に規格化したものである。

非常に印象的なグラフである。ある限られた範囲の風向で、ある大きさ以上の強い風が吹くとき大雨になっている。上空850hPa面における南南西~東方向からの強風が主要因である。暖候期に、この地域に南南西~東方向から吹きつける大気には大量の水分が含まれている。大台ヶ原山系等の走向は、ほぼ南北。尾鷲は東側にある。上空の風は地衝風に近いので、東に高気圧、西に低気圧があると、南から北へ吹く。地上付近では大気に摩擦が働くため、高気圧から低気圧へ吹き込む成分が出てくる。つまり、南東から北西へ吹く。この上層・下層の風の連携が重要である。

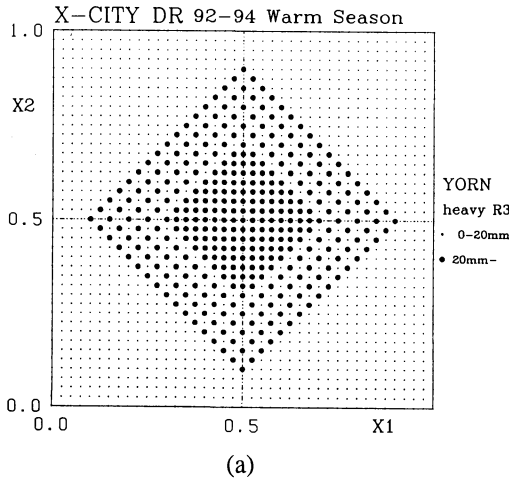
下層の風が臨界値より大きい東成分を持ち、海洋経由の風向範囲にあれば、充分湿潤であり、後背山系による強制上昇により凝結熱を得る。上層の湿潤大気も巻き込んで強い雨となる。上昇し雨を落として役割を終えた大気は、上層の強い風が運び去る。水分(燃料)補給と着火と延焼と排気のサイクルが、地形と海洋と風の特異な組み合わせによって実現される。

ここで補足する。「第4図のような関係がわかれば、自分でも予測できる」と思われるだろう。(その通り)。

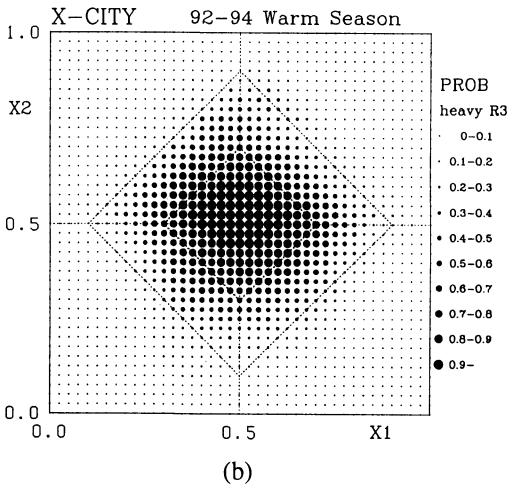
ところで、風向、風速の2変数の線形式では表現できないことに注意しよう。風向、風速の範囲を指定する条件式なら比較的うまくいきそうだ。(とても簡単)。

もし、3つ以上の因子が線形でない関係でかかると、やっかいになってくる。(できれば避けたい)。

さらに、日本全国の20kmメッシュの領域毎に、因子のあらゆる組み合わせを図示し、関係を検討して、




(a)



(b)

第5図 臨界現象のテストパターンと学習。●は、20 mm/3 h 以上の大雨を想定。(a) テストパターン、(b) 学習結果。黒丸は大雨生起確率。

個別的な関係式を発見し、それをプログラミングし、更に常時メンテナンスを続けるか。(絶対に避けたい)。ニューラルネットワークは、そのような膨大で苦痛を伴う作業を自動的にやってくれる。そこが最大のメリットである。ここでは因子の大きさを0~1の範囲に規格化している。その理由は、因子によって代表的な数値の大きさが異なるためである。たとえば、最大風速は0~100 m/s、風向は16方位に変化する。渦度の値は10のマイナス6乗の大きさである。それぞれの因子は同程度に重要だと仮定して出発するので、大きさを揃える訳であ



第6図 ニューラルネットワークによる、尾鷲付近の3時間平均雨量の学習。●は、20 mm/3 h 以上の大雨と判定。


る。それならば0~100の範囲でもよいのか？

普通は、各因子の変化する範囲が0~1であるときに効率が良くなるように、原形シグモイド関数や学習率や初期重みの範囲を決めて固定するのがふつうである。そうすると、どんな問題にも同一のニューラルネットワークで対応できるからである。0~100等でももちろん良い。ただし最適な調整を全てやり直す必要がある。

上述のように、ある臨界範囲に達すると顕著現象が発生する場合、ニューラルネットワークはうまく学習できるだろうか？ 第5図(a)は、2つの因子がある臨界範囲に達すると顕著現象が発生するとしたテストケースである。臨界領域を90°回転し、臨界領域を2段階、出現確率50%と100%の2つの領域とし、より一般的にした。第5図(b)は、その学習結果である。当該顕著現象の出現確率を出力させている。このような状況でも学習能力が高いことを示している。

第6図は、ニューラルネットワークで上述の尾鷲付近の3時間あたり的大雨発生を学習した結果である。●は大雨になる確率が50%以上と判定して、実際に大雨が降った事例、■は空振りの事例である。判定の実効精度は0.5であった。独立資料による予測精度も同程度であった。地形性的大雨は、顕著現象の予測としては幸運なケースである。ここで、N(●, ●)は、(予測=大雨, 実況=大雨でない)の事例数、実効精度は次式で定義される。

$$\text{実効精度} = \frac{N(\bullet, \bullet)}{N(\bullet, \bullet) + N(\bullet, \cdot) + N(\cdot, \bullet)}$$



第7図 天気(晴れ/曇り)予測用のニューラルネットワーク構成例. 左端は入力因子, 右端は出力(晴れ/曇り).

3. 天気予測

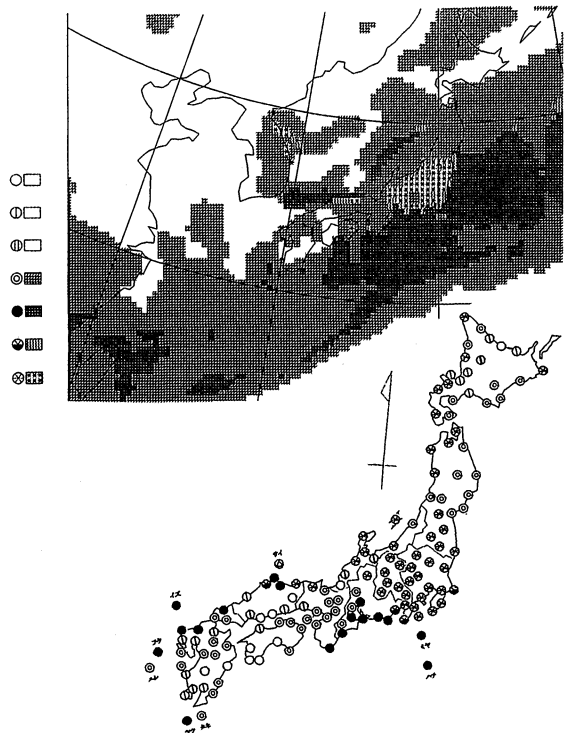
最も身近な例としてニューラルネットワークを天気予測へ応用してみよう。晴れ/曇りは、気象観測法に従って気象観測者が判定しているが、今、日照時間という自動観測量で天気(晴れ/曇り)を判定することを考えよう。計算機処理に向いているし、設置点も多いから将来的には有利である。

一般に、天気が良いほど日照時間は多くなる。全国110気象官署での「日照時間と目視観測の天気」とを比較調査した結果では、3時間のうち1.5時間以上の日照時間があれば「晴れ」と判別すると対応が良いことが確かめられている。

第7図は、そのニューラルネットワークの例である。ある20km平方領域での3時間の日照時間を予測する。そのための入力値として、その領域の中心における、その時間帯の中央の時刻に相当する数値予報値(内挿値)を使う。雲が発生するかどうかは、鉛直各層の相対湿度 Rh や大気的不安定さ ΔT や降水の予報値 FRR 等が関係深い。それらを入力しよう。そして該当する3時間の積算日照時間を予測させる。50%(1.5h)以上の日照であれば晴れ、50%以下の日照であれば曇りと判定する。


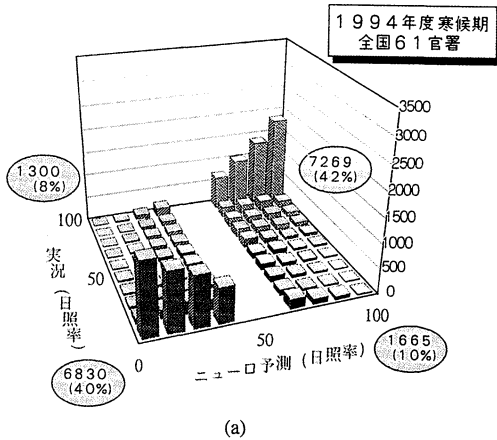
実際に天気予測した例と対応する天気実況が第8図である。1996年2月18日に関東に大雪が降った。その日の天気予測結果を表わしている。降水予測は数値予報(JSM=日本域スペクトルモデル)そのまま、降水が雪になるかは、雨/雪判定ダイアグラム(説明省略)にしたがって判定した。晴れ/曇りは上記のように日照

JSM 1996 2 17 12Z T= 12



第8図 ニューラルネットワークによる天気予測例(上図は予測, 下図は実況). 1996年2月18日, 関東は大雪となった.

時間予測を経由して判定した。完璧とはいかないが、なかなか良い予報であった。もちろん、他の因子もテストして、更に改善していくことも可能である。





第9図 天気(晴れ/曇り)予測の精度検証. 1994年度寒候期, 全国61官署. (a) 予測 $\geq 60\%$, 予測 $< 40\%$ の場合, (b) $40\% \leq$ 予測 $< 60\%$ の場合.

4. 天気のゆらぎと快晴

第9図は, ニューラルネットワークによる1994年度寒候期の全国61気象官署を対象とする, 20 km 平方領域, 3時間幅の日照率予測と実況日照率の比較図である. 晴れ/曇りの判定としては, 予測 $\geq 50\%$ のとき実況 $\geq 50\%$ であるか,あるいは, 予測 $< 50\%$ のとき実況 $< 50\%$ であれば正解である.

予測日照率 $\geq 60\%$ か予測日照率 $< 40\%$ のとき, 予測は良く当たる. 一方, $40\% \leq$ 予測日照率 $< 60\%$ のとき正答率は55%と低い. 後者は全体の20%程度である.

これは, 予測時間帯(3時間)に天気に移り変わっていることと関係している. 全国の気象官署の天気観測と日照時間とを比較すると, 天気が3時間後に, 晴



第10図 忘却する学習の効果. $(a \cap d) \cup (b \cap e)$ を学習させる. (a) 通常学習のリンク, (b) 忘却のある学習のリンク実線は正の重み, 破線は負の重み.

れ \rightarrow 悪天, 悪天 \rightarrow 晴れと変化しているケースは全体の20%程度である. そのときの日照時間は, 20%~80%のどの値も同程度の分布である. 理由は, 天気が推移するとき, 3時間内の晴天と悪天の混合比率は, ほぼ等確率となるからである.

天気の移り変わりには, 大きなじょう乱の接近, 通過のように, 一方向のトレンドの場合と, 冬型気圧配置の日本海側のように, 寒気の吹き出しに伴う小じょう乱にさらされている場合がある. 特に後者の状況下では, 天気は不規則にゆらいでいて, 正確に予測することは困難である.

一方, 予測日照率 $\geq 90\%$ のとき, 晴れ予測の適中率は非常に高い. そのように確度が大変高い晴れ予測を, 別のカテゴリー(例えば, 快晴とか爽晴)で出すことは有益である. 利用者は, 行楽や野外活動を計画・実行するとき, よりの確に判断できるようになるだろう.

5. 忘却のすすめ

ニューラルネットワークを気象に応用し, 入力因子と目的とする変数との間の関数関係を学習させ, その対応が良好であったとしても, どの入力因子が主要因

なのかを知りたくなる。

忘却項を加えるという学習法がある。それは、常にリンクの大きさ（重み）が細くなっていく方向に反学習させる項である。学習1回あたりの忘却量を大きくとると、学習するより忘却するので、学習は進まなくなる。忘却量はかなり小さくとるが、積算効果は著しい。役に立たない因子から出ているリンクは次第に小さくなって、やがて視界から消える。第10図は、その効果をテストしたものである。

学習方法は、例えば、階層型5-5-1の入力層に1か0の数値をランダムに入力する。aとdの入力が1の場合、あるいはbとeの入力が1の場合に、教師データを1とする。それ以外は0とする。このようにして論理関係（aかつd）または（bかつe）を学習させる。第10図では、学習後のリンクの大きさを重みに比例（正のとき実線、負のとき破線）させている。（a）は通常の学習である。リンクのありさまは複雑で、これから学習させた論理関係を推察することは不可能である。（b）は忘却学習である。リンクのありさまは明快で、論理関係を可視化させている。少なくとも、どの因子が重要であり、どの因子が関係し合っているかが見える。

この意味を、前回の仕組みと関連づけて考えよう。入力層から中間層へのリンクが大きいことは、シグモ

イド関数を左右から圧縮する変形である。だから、その入力因子が変化すると関数値は急変するようになる。リンクが小さいことは、シグモイド関数を左右へ伸張する変形である。その入力因子が変化すると関数値はゆっくりと増加するか減少する。中間層から出力層へのリンクが大きいと、その変形シグモイド関数を重視した合成をする。小さいと、軽視した合成をする。そのように意味合いは少し異なるが、リンクの大きさは重要度を表わしている。

6. おわりに

毛色のちがった分野に対して、人は二の足を踏む。ニューラルネットワークは特にそうで、使えるかどうかの判断材料を得るためにさえ相当の先行投資を要求されると困ってしまう。また、先行投資してみたもののポイントがつかめないと、努力が無駄にならないかと不安になる。そんなとき神髄とまではいかななくても、重要なポイントを具体例を交えてわかりやすく説明したものがあると助かる。気象談話室の主旨をそのように理解しています。筆者は、偶然か因縁かこの分野に立ち入ったとき、長く途方に暮れました。筆者の体験などごく僅かなものでありますが、少しでもお役に立てば幸いです。最後に、査読をしてくださった方々にお礼を申し上げます。