

応力予測ニューラルネットワーク

Stress Prediction Artificial Neural Network

塩 見 和 之* 渡 邊 生*
Kazuyuki Shiomi Sei Watanabe

要 旨

ニューラルネットワークを利用して、エンジンのクランクシャフトの6箇所の形状寸法から、クランクピン・フィレット部の応力集中係数を算出するシステムを開発した。

ニューラルネットワークの学習用データベースの作成には有限要素法による計算結果を用い、学習計算には予測精度の向上のために開発した「適合伝達関数アルゴリズム」を用いた。また、単気筒汎用エンジンおよび、多気筒船外機エンジンのクランクシャフトに適用した際の応力集中係数の予測誤差は、計測値に対して-6.9～+6.3%であった。

このシステムを用いることにより、設計者はフィレット部に発生する集中応力を短時間に、しかも高い精度で計算することが可能となった。

ABSTRACT

By using an artificial neural network, the system that predicts the stress concentration factor of the crankpin fillet from 6 characteristic dimensions of a crankshaft has been developed.

In order to achieve accurate prediction, “Adaptive Transfer Function Algorithm” has been developed as learning method of Neural Network and learning data have been obtained by Finite Element Method. The experiments were conducted using crankshafts of small utility engines and outboard motors, of which results showed that the stress concentration factor was predicted with -6.9 to +6.3% error.

Making use of this system, designers are enabled to calculate the concentrated stress on the crankpin fillet precisely in a short time.

1. ま え が き

クランクシャフトの疲労破壊を引き起こす要因のひとつに、クランクピン・フィレット部の応力集中がある。クランクシャフトの設計にあたっては、この応力集中を充分に考慮して形状寸法を決定することが望ましい。しかし、一般にクランクピン・フィレット周辺の形状は複雑で、応力集中の度合いを定量的に求めることは難しい。

クランクピン・フィレット部の応力集中を予測する方法として、従来からいくつかの実験式が提案されてきた^{1) 2)}。これらの式は、実験値をもとにクランクシャフトの形状諸元とクランクピン・フィレット部の応力集中係数との関係を定式化したものである。なお、この応力

集中係数は、クランクピン・フィレット部に発生する応力の、クランクシャフト全体をピン径相当の梁とみて求めた基準応力に対する倍率である。これらの式は、発生する応力を簡便に計算できる利点は大きい、適用できる寸法の範囲に制約があること、フィレット部まわりの三次元的な形状の影響を十分に考慮できず高い予測精度が得られないことから、軽量化を狙った最適設計に利用するのは困難であった。

これに対し、近年は精度向上のためコンピュータを利用した有限要素法 (FEM) や境界要素法 (BEM) などによる解析が多く行われるようになった³⁾。これらの手法には、荷重を受けた場合の応力分布や変形形状などを総

* 朝霞東研究所

合的に解析できるメリットはあるが、精度の高い解析のためには、詳細なモデル化や専門的知識が不可欠であることから、解析は専任者によって行われる場合が多い。最近では、設計者が自ら解析を行える手法として、有限要素の自動生成（オートメッシュ）⁴⁾や高次の有限要素を用いるP法⁵⁾などが注目を集めているが、依然として解析には多大な計算量が必要とされる。

このように、設計の現場では応力集中を正確に予測し、クランクシャフトや関連するエンジン構成部品を最適な諸元で設計するための簡便なツールが求められている。

2. 狙いと手法

本報に述べる手法の狙いは、実験式なみの簡便さで高精度にクランクピン・フィレット部の応力集中係数を予測することである。そのため、あらかじめ応力集中係数と、フィレット部まわりの形状に関するデータベースを作成し、関数により近似することで応力集中係数を求めることを考えた。これは従来から提案されている、実験値をもとに実験式を導く考え方と基本的に変わりはないが、

1. 信頼性の高いデータを多数用意する
2. データ群の示す傾向を正しく表現できる関数を用いて近似する

ことにより高精度化を図ることとした。

まず、データを得る手法として、有限要素法による計算を用いる。これによれば精度の高い応力計算が可能で、しかも実験では避けられない測定誤差によるデータのばらつきも取り除くことができる。算出した応力値を応力集中係数に換算し、クランクピン・フィレット部周辺の形状を特徴づけるいくつかの寸法と組み合わせて、データベースを作成する。

また、データを関数近似する手法として、ニューラルネットワークを利用する。これはコンピュータを用いて生物の神経回路網の動作を模擬する技術で、多数のデータから非線形の近似関数を生成する機能をもつことが知られている。この近似関数を作成するためには、多くの計算が必要とされるが、得られた近似関数を用いれば、解を算出することは容易である。即ち、クランクシャフト形状から、応力集中係数を短時間で求めることが期待できる。

3. システムの構築

3.1. データベースの作成

今回対象とした一体型クランクシャフトのワンスロー部分において、クランクピン・フィレット部の応力集中に大きく影響を与える寸法として、下記の6個の形状諸元を選び出した（Fig. 1）。なお、相似形のクランクシャフトに対して応力集中係数は常に同じ値となるため、クランクピン径を1として寸法を無次元化した。

- | | |
|--------------|-------|
| ① クランク半径 | (Rcr) |
| ② ジャーナル径 | (Dj) |
| ③ ピンフィレット部半径 | (Rf) |
| ④ ウェブ厚み | (Bw) |
| ⑤ ウェブ幅 | (Sy) |
| ⑥ ショルダ高さ | (Sz) |

次に、これらのクランク形状を有限要素によってモデル化し、そのクランクピン・フィレット部の応力を求め、先述の基準応力に対する倍率として応力集中係数を算出した。これにより、無次元化された形状寸法（以下、形状寸法という）と対応する応力集中係数が得られる。パラメトリックに寸法を変更しながら、総計約130種のクランクシャフト形状に対し計算を行い、データベースとした。その一部をTable 1に示す。

有限要素モデル（Fig. 2）は、形状の対称性を考慮してワンスロー部分の1/4をモデル化し、有限要素には精度上信頼性の高いアイソパラメトリック二次要素を使用した。拘束条件として、軸受部を点支持、クランクピン中央部に集中荷重を与えた。また、全てのモデルに対してピンフィレット部のメッシュの分割数を統一し、モデル化の差異による計算精度のばらつきを最小限に抑え




Fig. 1 Characteristic Dimensions of Crankshaft

Table 1 Form of Database

No.	Characteristic Dimensions						Stress Concentration Factor α
	Rcr	Dj	Rf	Bw	Sy	Sz	
1	0.7	0.8	0.04	1.0	1.24	1.24	3.24
2	1.0	0.8	0.04	1.0	1.24	1.24	4.02
3	1.4	0.8	0.04	1.0	1.24	1.24	5.24
⋮							
⋮							
⋮							

ている。なお、計算に際しては、形状寸法の組からほぼ自動的にモデルを作成するプログラムを作り、作業を容易にした。

3.2. 関数近似手法に求められる条件

いま、横軸にクランクの形状諸元のひとつを取り、縦軸に応力集中係数をとってグラフを描くと、データベースに含まれるデータは点列として表される (Fig. 3~5)。これらの点列を曲線によって結ぶことで、データベースに含まれない形状に対しても応力集中係数を予測できる。今回の問題では、この横軸に当たる形状諸元が6種類であり、点列を近似することは7次元の空間内に曲面を表す関数を作成することに相当する。また、形状寸法と応力集中係数の関係はそれぞれ相互に関連しあっており、




Fig. 2 Analysis Model of Crankshaft




Fig. 3 Relationship between Stress Concentration Factor and Web Thickness




Fig. 4 Relationship between Stress Concentration Factor and Fillet Radius of Crank Pin




Fig. 5 Relationship between Stress Concentration Factor and Web Width

その取り扱いが容易ではない。

例えば、ウェブ厚みと応力集中係数の関係(傾向)は、クランク半径の大小によって大きく変化する(Fig. 3)。また Fig. 4 はピンフィレット部半径と応力集中係数の関係を示したものであるが、寸法をゼロに近づけると応力集中係数は大きな値に発散する。これに対し Fig. 5 ではジャーナル径が大きくなるにつれ、応力集中係数は他の形状寸法で決まる、ある値に近づく(飽和する)。

以上の条件を整理すると、関数近似の手法に求められる条件として、次の二点が挙げられる。

1. 多次元の近似処理ができること。
(多変数関数を生成できること)
2. 発散、飽和といった傾向を正しく表現できる非線形の関数を生成できること。

3.3. ニューラルネットワークによる関数近似

一般的なニューラルネットワークの概念図を Fig. 6 に示す。図中の●印がニューロンを示し、階層的に並んだニューロン間がネットワーク状に結ばれている。このようなニューラルネットワークは全体として多変数関数のようにふるまう。すなわち、図中の左端にある各々のニューロンにある数値の組が入力されると、個々のニューロンは一定の規則に従って入力値から出力値を計算し、右端からひとつの数値を出力する。本報に述べる手法では入力としてクランクシャフトの形状寸法を与え、出力として応力集中係数を取り出すことで、クランクシャフトの応力予測問題に利用する。

このネットワークがつくり出す多変数関数の特性は、個々のニューロンに対して定義される関数(伝達関数)と

数値(結合係数、しきい値)によって決定される。ニューラルネットワークは、多数の入出力データの組をもとに、これらの数値を自動的に設定し、データの示す入出力関係をネットワーク上に作り上げる計算を行う。この計算はニューラルネットワークの「学習」と呼ばれており、ここでは多変数関数によってデータの近似を行うことに相当する。

従来よりこの学習計算には、バックプロパゲーション(誤差逆伝播法)とよばれる手法をはじめ、各種のアルゴリズムが提案されてきた⁶⁾。最も一般的なものは、伝達関数としてシグモイド関数とよばれる飽和型の関数を用い(Fig. 6)、ネットワーク内の数値(結合係数、しきい値)を修正してゆく手法であった。しかし今回の問題では、必要とされる曲線に発散するものも含まれるため従来の手法をそのまま適用することはできない。

今回の問題にニューラルネットワークを利用するに当たり、先に述べた近似手法に対する条件を満足する手法として、適合伝達関数アルゴリズム(または適合ニューロンアルゴリズム)を開発した(APPENDIX(1)を参照)。この手法は以下の二つの特長をもつ。

1. 飽和型や発散型、あるいは双方の関数を混合した複合型の伝達関数を使用できる。
2. 学習により、伝達関数の特性自体が変化・適合する。

この手法を用いることで、直観的な類推に基づいた自由な伝達関数を使用でき、従来にはない多様な曲線(曲面)による近似が可能となった。

3.4. 関数近似の結果

関数近似を行った結果の一例を Fig. 7 に示す。与えられたデータ点の近傍を通る、滑らかな曲線(曲面)を形成することができた。

今回の問題に適用したネットワークの構造を Fig. 8 に示す。図中の階層状に並んだニューロンの第2層目(中間層)のニューロンに、発散・飽和の双方に対応できる複合型の伝達関数を適用した。これらの関数の形式や、中間層に配置するニューロン数などネットワークの構造は近似の精度や曲線(曲面)の形状を勘案して決定した。

ニューラルネットワークの行った学習の経過を Fig. 9 に示す。横軸は修正計算の反復回数(学習回数)、縦軸は学習を行った各データに対する誤差二乗値の平均値で




Fig. 6 Architecture of Artificial Neural Network




Fig. 7 Result of Functional Approximation




Fig. 8 Stress Prediction Neural Network




Fig. 9 Learning Curve

ある。計 7,400 回の反復計算 (学習) の結果、各データに対する誤差二乗値は平均で 5.9% となった。また前述のように、学習のために用意したデータの数は約 130 組であるが、この数は、全ての入力値の組み合わせに対して内挿によって近似関数をつくるという観点からみると、必ずしも十分な数ではない。これらの点に関しては別途、考察を加える (APPENDIX (2) を参照)。

4. 応力予測性能の検証

単気筒汎用エンジンおよび、多気筒船外機エンジンの合計 16 種のクランク形状について、クランクピン・フィレット部に歪みゲージを貼付し、静的に応力を測定した結果を用いて、本手法による応力予測の精度を検証した。ニューラルネットワークによる計算値を、計測値と比較した結果、誤差は $-6.9 \sim +6.3\%$ となり (Fig. 10)、従来より利用されてきた実験式に比べ、大幅に精度を向上することができた (Fig. 11)。なお、検証に用いたクランクシャフト形状は、ニューラルネットワークの学習に用いたデータベースには含まれていない。また、図中で応力集中係数の値が 3.0、および 5.5 付近の二群に分かれているが、これは前者が単気筒汎用エンジン、後者が多気筒船外機エンジンのクランクシャフトであることによる。




Fig. 10 Result of Verification (Neural Network)




Fig. 11 Result of Verification
(Conventional Formulation)

5. 結 論

クランクシャフトの形状寸法と、有限要素法の計算結果からなるデータベースをもとに、ニューラルネットワークを用いてクランクピン・フィレット部の応力集中係数を予測するシステムを開発し、以下に示す成果を得た。

- (1) ニューラルネットワークの学習法として、適合伝達関数アルゴリズムを導入し、少ないデータから各々の目的に適った近似関数を作成することを可能とした。
- (2) クランクピン・フィレット部の応力集中係数を、短時間に、かつ高精度に予測することが可能となった。歪みゲージを用いた計測値との誤差は $-6.9 \sim +6.3\%$ の範囲に入った。

6. あとがき

このシステムの利用により、設計者はエンジン設計の現場でクランクシャフトに関する設計感度解析を対話的に行うことができ、クランクシャフト周辺部品の共用化や、加工上の制約などを考慮した上での最適設計を行うことが可能となる。また、データベースに新たな解析結果を追加、蓄積することにより予測精度を向上させ、適用可能なクランク形状の範囲を拡大することができる。

本報に示したニューラルネットワークとデータベースを組み合わせた手法は、工学分野における多くの最適化問題、逆問題などに適用が可能であると考ええる。

参考文献

- 1) 新井淳一：一体型クランク軸の曲げ形状係数、日本機械学会論文集、30巻218号(昭39-10)
- 2) H. Maass: Gestaltfestigkeit von Kurbelwellen nach Forderung der Klassifikationsgesellschaften, MTZ25 (1964) 10-391
- 3) Milan Svoboda und Walter Bauer: Berechnung von Spannungen in den Hohlkehlen von Pkw-Kurbelwellen mit der BEM, MTZ47 (1986) 3-95
- 4) 渡辺 史ほか：ピストン、クランク用FEMプリプロセッサシステムの開発、自動車技術会 学術講演会前刷集902, 1990-10
- 5) I. Babuska, B. Szabo, I. N. Katz: The p-version of the finite element method, SIAMJ. Numer. Anal. Vol.18, pp.515-545, 1981
- 6) Rumelhart, D. E.: Parallel Distributed Processing Vol.1, 2, The MIT Press, 1986

APPENDIX

(1) ニューラルネットワークの

動作と学習アルゴリズム

階層型ニューラルネットワークの構造図をFig. 12に、それを構成するニューロンの概念図をFig. 13に示す。第 n 層第 s 番目のニューロンは第 $n-1$ 層の出力をもとに下式に従って出力値 O_s^n を計算する。式中 I_s^n は入力値、 $W_{r,s}^{n-1,n}$ は第 $n-1$ 層第 r 番目のニューロンとの間の結合係数、 θ_s^n はしきい値、 $f(x)$ は伝達関数を示す。

$$I_s^n = \sum_r W_{r,s}^{n-1,n} O_r^{n-1}$$

$$x = I_s^n - \theta_s^n \quad \dots\dots (1)$$

$$O_s^n = f(x)$$

Fig. 12の第1層に入力値を与えるとネットワークは上式の処理を行い、第 N 層から出力値を発生する。複数の入力値から出力値を算出するという多変数関数とし

ての挙動は、ネットワーク内の W 、 θ および $f(x)$ により決定される。これらを修正し最適化することにより、多数のデータ（教師データ）の入出力関係を得ることを、ニューラルネットワークの「学習」とよぶ。従来、この修正計算は W 、 θ のみを対象とするのが一般的であったが、本テーマで用いた適合伝達関数アルゴリズムは、これに加えて伝達関数 $f(x)$ の関数形をも修正し最適化することにより、学習性能の向上とスピードアップを図るものである。

学習の到達度を下式によって評価し、これを極小化することを考える。

$$E = \frac{1}{2} \sum_j (T_{oj} - O_j^N)^2 \quad \dots\dots (2)$$

ここで、 T_{oj} は出力教師データ（有限要素法による計算で求めた応力集中係数）、 O_j^N は対応する入力教師データ T_{ij} （6つの形状寸法）を第1層に与えた場合のネットワークの出力である。

いま、伝達関数 $f(x)$ の特性を決める複数の任意のパラメータを km とおけば、 E はネットワーク内の全 W 、 θ および km の関数であるから、その全微分は次のように書ける。

$$\Delta E = \sum \frac{\partial E}{\partial W} \Delta W + \sum \left(\frac{\partial E}{\partial \theta} \Delta \theta + \sum_m \frac{\partial E}{\partial km} \Delta km \right) \dots (3)$$

ここで W 、 θ 、 km に対し下式の修正を繰り返すことにより E を極小化することができる。

$$\begin{aligned} \Delta W_{r,s}^{n-1,n} &= -\alpha \left(\frac{\partial E}{\partial W} \right)_{W=W_{r,s}^{n-1,n}} \\ \Delta \theta_s^n &= -\beta \left(\frac{\partial E}{\partial \theta} \right)_{\theta=\theta_s^n} \quad \dots\dots (4) \\ \Delta km_s^n &= -\gamma_m \left(\frac{\partial E}{\partial km} \right)_{km=km_s^n} \end{aligned}$$

なお、式中の α 、 β 、 γ_m は小さな正の定数で、学習係数とよばれる。

伝達関数の例として本文中の応力予測ニューラルネットワークの中間層に用いた伝達関数を下に示す。

$$f(x) = k_1 x + k_2 x^2 + \frac{k_3}{1 + e^{-k_4 x}} \quad \dots\dots (5)$$

この関数は x の増加（減少）とともに発散する第1、2項と、飽和する第3項から成る複合型の伝達関数で、式中の km ($m=1\sim 4$) が関数の特性値となる。即ち、 k_1 および k_2 は1次、2次関数の、 k_4 はシグモイド関数の勾配であり、 k_3 はシグモイド関数の値域の拡大倍率である。Fig. 14 に、これら特性値によって関数の挙動が大きく変化する様子を示す。

適合伝達関数アルゴリズムによれば、(5)式などの任意の微分可能な関数を伝達関数として使用でき、さらに伝達関数の特性を決める任意のパラメータを学習の対象とすることができる。また、学習によりニューラルネットワークが自ら伝達関数の特性を最適化してゆくため、少ない回数で誤差の少ない学習が可能となる。




Fig. 12 Multilayered Neural Network




Fig. 13 Mathematical Model of Neuron

(2)ニューラルネットワークの学習に関する考察

ニューラルネットワークで生成した近似関数は、各データに対し誤差を生じ、必ずしも元のデータの点列上を通らない。このため今回のような問題では、ニューラルネットワークによる関数近似の精度と、近似関数を予測に用いた場合の予測精度とを分けて考える必要がある。

例えば少ない学習データを、ニューロン数の多い大規模なネットワークに学習させると、近似誤差は限りなくゼロに近づく。しかし、多くの場合近似曲線はねじ曲がり、意味のない変曲点を持つ。これは高次の多項式を用いてデータを補間した場合と同様の現象で、ニューラルネットワークの「過学習」とよばれる (Fig. 15)。過学習により作られた近似関数はデータの近似精度は高いが、データ群のもつ全体的な傾向を反映できず、予測精度は内挿部・外挿部ともに低い。過学習を防ぐためにニューロン数を少なくすると、従来のニューラルネットワークでは、近似精度と予測精度の双方が悪化する。

一方、このような問題を避けるため、全ての変数に対し内挿によってデータを補間し、予測を行うことを考える。いま仮に、ひとつの入力変数に対し、その両端の値および全体の傾向を表すために4点のデータが必要であるとする。入力変数6個に対してこの全ての組合せを考えると、必要なデータの数は $4^6 = 4096$ 個となる。補間に用いるデータの数を増やせば、近似精度と予測精度とともに満足することができるが、データ作成に要する計算量を考慮すると現実的ではない。

これらの問題点を解決するため、今回のニューラルネットワークでは、飽和・発散の複合型の伝達関数を用い、内挿とはならない領域に関しても形状寸法に対する応力集中係数の傾向を保持するような学習を行った。さらに必要最小限のニューロンでネットワークを構成することにより、過学習を防止した。

これにより、中間層が6個の小規模ネットワークとしては比較的良好な、近似誤差5.9% (二乗誤差平均) という結果が得られた。また、約130個という少ないデータから、飽和・発散などの傾向を反映した近似が可能となり、高い予測精度を実現することができた。




Fig. 15 Approximation by Over Learned Neural Network




Fig. 14 Composite Transfer Function

■著者■



塩見 和之



渡邊 生