

VI-6

ニューラルネットワークによる道路斜面の崩壊予測について

八戸工業高等専門学校 正会員 齊藤 進

1. はじめに

本研究はニューラルネットワークを用いて、降雨要因（または降雨要因と地形・地質要因）と道路斜面の崩壊・無崩壊との写像関係を構築し、降雨時どの程度の崩壊・無崩壊予測が可能であるかを明らかにしようとするものである。

2. 研究方法

東北地方の国道における斜面崩壊の事例データ（国土交通省提供）と被災箇所における過去10年の降雨データを収集し、崩壊・無崩壊降雨の雨量データを表1に示すように4種類の降雨要因を組み合わせて16ケースに整理する。また、各崩壊箇所の地形（低・高、緩・急など4区分）と地質（堆積岩、花崗岩など6区分）のデータを準備する。次に降雨要因と地形・地質要因または降雨要因のみを入力とし、崩壊(1)か無崩壊(0)かを出力としたニューラルネットワークの学習を行う。学習済みとなったニューラルネットワークはすべて検証データによって、半判別的な中率が求められ信頼度が確かめられる。さらに判別的な中率の高いシステム（学習済みニューラルネットワーク）によって、降雨継続中の崩壊・無崩壊の予測を行い、リアルタイムでの予測の可能性を明らかにする。

なお、1降雨の区切りは8時間以上の無降雨期間とし、崩壊降雨については崩壊時間まで、無崩壊降雨については1時間最大雨量時間までの降雨によって累積雨量等の各項目の評価を行う。実効雨量は対象としている時間から前の降雨の影響を考慮した累積雨量である。

3. ニューラルネットワークの学習と検証

全データは180個で120個（崩壊34個、無崩壊86個）を学習に、60個（崩壊21個、無崩壊39個）を検証に用いる。また雨量が非常に小さいにも拘らず崩壊が生じた降雨や、逆に雨量が極めて大きいにも拘らず崩壊が生じてない降雨など例外的な降雨を除いて155個のデータセットを用意する。155個のうち110個（崩壊31個、無崩壊79個）を学習に、45個（崩壊15個、無崩壊30個）を検証に用いる。

ニューラルネットワークの学習と検証はA～Fの6シリーズに分けて行う。Aシリーズは全データを用いた、地形・地質要因と降雨要因を入力としたシステム、Bシリーズは全データを用いた、降雨要因のみを入力としたシステム、Cシリーズは例外的降雨要因を削除し、地形・地質要因と降雨要因を入力としたシステム、Dシリーズは例外的降雨要因を削除し降雨要因のみを入力としたシステム、EシリーズはCシリー

ズの学習データと検証データを入れ替えたシステム、FシリーズはDシリーズの学習データと検証データを入れ替えたシステムである。学習と検証の結果を図1～図4に示す。図1、図2より、学習時には要因数の少ないケースB1、D1、F1、B2、D2、F2、B16が低い中率であるが他のケースは良好な中率を示している。また図3、図4から検証時には、ケースD4、D7、F7、D9が、80%程度の的中率を示し、良好な崩壊・無崩壊判別システムとなっていることが分かる。さらに図1、図2から学習では、A、C、EシリーズがB、D、Fシリーズよりの中率が大きくなっており、これは地形・地質要因を考慮するとデータが多様化し、学習的中率が大きくなることを示している。図3、図4より検証では、D、FシリーズがA、B、C、Eシリーズに比べると多くのケースで的中率が大きい。すなわち検証時には、例外的降雨要因と地形・地質要因を削除した多様性の少ないデータの方が的中率は大きくなることがわかる。

4. 良好な判別システムによる崩壊予測

次に良好な判別システムとしてケースD4とケースD9を選び、崩壊・無崩壊予測及び時間経過に伴う崩壊予測を行う。その結果、ケースD4では15ケース中9ケース、ケースD9では15ケース中10ケースで崩壊を予測することに成功している。ケースD4による経時的な予測のうち崩壊降雨で予測が的中した降雨の一例を図5に、無崩壊で予測が的中した降雨の一例を図6に示した。図5に示すケースのように崩壊が早い段階から予測できればその意義は大きいといえる。

表1 降雨要因の組み合わせ

ケース	短期降雨要因	長期降雨要因	時間的要因	降雨前雨量要因
1	1時間最大雨量	累積雨量		
2	1時間最大雨量	実効雨量(T=24)		
3				
4	1時間最大雨量	累積雨量	継続時間	前3日間雨量
5				前7日間雨量
6				
7	実効雨量(T=1)	累積雨量	継続時間	前3日間雨量
8				前7日間雨量
9	実効雨量(T=3)	累積雨量	継続時間	前3日間雨量
10	実効雨量(T=6)	累積雨量	継続時間	前3日間雨量
11	58時間雨量	累積雨量	継続時間	前3日間雨量
12	1時間最大雨量	実効雨量(T=12)	継続時間	前3日間雨量
13				
14	1時間最大雨量	実効雨量(T=24)	継続時間	前3日間雨量
15				前7日間雨量
16	1時間最大雨量	累積雨量	平均雨量	




図1 学習における(崩壊+無崩壊)降雨の判別率的中率




図2 学習における(崩壊+無崩壊)降雨の判別率的中率




図3 検証における(崩壊+無崩壊)降雨の判別率的中率




図4 検証における(崩壊+無崩壊)降雨の判別率的中率




図5 崩壊降雨における崩壊可能性の経時変化(的中)




図6 無崩壊降雨における崩壊可能性の経時変化(的中)

5. おわりに

全般に図5に示されるような時間経過に伴う降雨のグラフが一つの山形をなす場合は予測的中しやすい。崩壊を予測できなかったケースにおいて、その原因として挙げられるのは、①小降雨が長時間(20~40時間)継続してから崩壊した場合(3ケース)、②突然、集中的な降雨があった場合(1ケース)、③降雨開始後すぐに集中降雨があった場合(1ケース)の3つである。逆に無崩壊である

のに崩壊を予測してしまっているケースにおいて、原因として挙げられるのは、①小降雨が長時間継続した場合(2ケース)、②不規則な降雨のタイプである場合(2ケース)、③全体的に累積雨量が大きい場合(2ケース)の3つである。このような判別システムを現行の管理規準に併用して、リアルタイムの予測を行うことができれば、より合理的な降雨時の道路管理が可能になると思われる。