

教師ありアンサンブル学習による地震とノイズの自動識別

溜瀧功史（気象研究所）

1 はじめに

緊急地震速報はもとより、一元化震源を迅速かつ効率的に作成するためには、自動処理が不可欠である。これまで、一元化震源については、2016年4月にPF法（溜瀧・他, 2016, 験震時報）を導入し、2016年熊本地震などで大きな役割を果たしてきた（Tamaribuchi, 2018, EPS）。また、2020年9月からはS-netの観測データを一元化震源に取り入れ、日本海溝沿いの地震活動の検知力及び震源精度が大幅に向上しているところである。

一方、自動処理において、ノイズ等による震源の誤決定は避けることができない課題である。自動震源の決定率（一元化震源カタログの個数のうち、自動震源で決定できた割合）の増加とノイズ数の減少はトレードオフの関係にある。地震の決定率を保ったまま、ノイズによる誤検知を減らすために、長年パラメータチューニングの試行錯誤が続いてきた。現在のPF法では、P相やS相の検出数や、走時残差の二乗平均平方根、震源誤差の閾値をそれぞれ条件として設定し、これらの条件の1つでも満たさない場合は、震源はノイズの誤決定であると判断し、出力しない。このようなルールベースの地震・ノイズ判別は、人間が理解しやすい一方で、パラメータの任意性が大きく、試行錯誤を繰り返す必要があった。

ところで近年、深層学習（Deep learning）の成功により世界的な人工知能ブームが巻き起こり、実社会において活用が進んでいる。地震学でも深層学習に限らず、機械学習手法の進展とライブラリの発達に伴い、運用ベースで多種多様な試みがなされているところである。

そこで、本研究では、機械学習を用いた自動震源決定処理におけるノイズイベントの低減について試みたので報告する。

2 データと手法

本研究では、2020年1月1日から2月29日までのPF法による自動震源を用いた。なお、S-netも用いた。震源及び検出値から、緯度、経度、検出数などの値を1地震につき229種類の特徴量として抽出し、これをデータとした。まず、地震波形を目視により確認し、地震とノイズの教師データセットを作成した（図1）。現状のPF法には、ノイズ等の誤検知が琉球諸島で多く、全体の5%程度含まれることが分かる。ここでは、カテゴリ0（図1a）及びカテゴリ1（図1b）を「地震」、カテゴリ4（図1e）を「ノイズ」としてラベル付けし、教師あり機械学習の分類問題として扱う。ラベル付けしたデータを学習データとテストデータが8:2になるよう分割し、学習データは29457個、テストデータは7365個の地震を用いた。

ここで、機械学習の一種であるアンサンブル学習によってノイズの頻度を低下させることを試みる。アンサンブル学習は性能の低い分類器（例えば決定木）を組み合わせ、性能の高い分類器を作成する手法である。大別してバギングとブースティングと言われる方法がある。ランダムフォレストは、バギングの一種で、学習データを復元抽出によって複数のサブデータセットを作成し、それぞれのサブデータセットに対して決定木で学習する手法である。個々の決定木（弱仮説器という）の分類性能は高くなくても、それらの多数決あるいは確率値の平均を用いることによって、分類性能を高くすることができる。AdaBoostは、ブースティングの一種で、より難しいデータに適応

(Adaptive) するように、弱仮説器が誤判別したデータの重みを更新していく (Boosting) 手法である。どちらかの手法が優れているというわけではないので、データに応じて手法を決める必要がある。そこで、本研究では、両者をそれぞれ検証し、分類性能が最も高いものを選択した。

本研究で用意した特徴量は 229 種類だが、これら全ての特徴量が地震とノイズの判別に寄与するわけではない。229 種類の特徴量から、真に判別に寄与する特徴量を選別することができれば、ブラックボックスと言われがちな機械学習における判別過程の可読性の向上に寄与するほか、過学習の抑制や成績改善に対する効果が期待される。そこで、本研究では、**Boruta** の方法による変数選択も行った。これにより、229 種類の特徴量が、183 種類に絞られた。

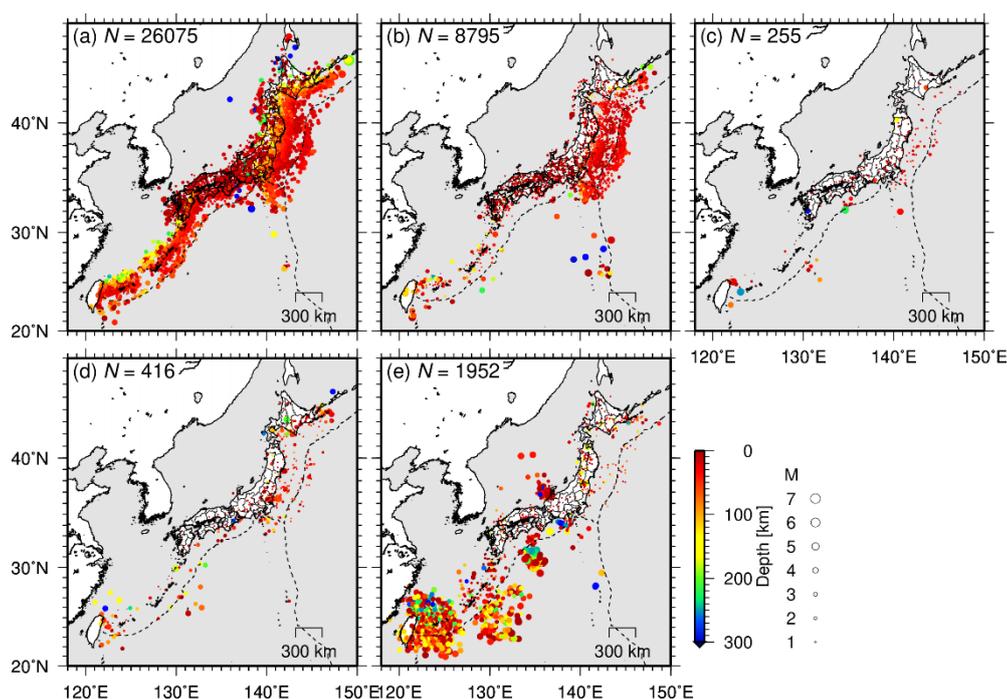


図 1 各カテゴリ (0-4) の震央分布図。色は深さを示す。(a) 一元化震源と一致した自動震源、(b) 地震で読み取りが概ね正しい、(c) 地震だが読み取りに誤りが多少ある、(c) 地震だが読み取りが大きく異なる、(d) ノイズ。(b-d) は、一元化震源とは不一致だったが、目視で確認したイベントを示す。

3 結果

学習の結果、ランダムフォレストでは、正しくノイズと地震に分類できた割合 (Accuracy) は 96.39%であった。また、地震のテストデータのうち、正しく地震と分類できた割合は 96.52%、ノイズのテストデータのうち、正しくノイズと分類できた割合は 94.23%であった。AdaBoost では Accuracy は 98.51%であった。また、地震のテストデータのうち、正しく地震と分類できた割合は 99.53%、ノイズのテストデータのうち、正しくノイズと分類できた割合は 81.49%であった。これは、震源決定数を 99%以上保ったまま、ノイズを約 1/5 (全体の 1%に相当) に低減できることを意味する。以上のように、機械学習によってノイズを大幅に低減できることが確認できた。これは自動震源による地震活動のモニタリングやカタログ作成の効率化に大きく貢献する。

謝辞：一元化震源を使用しました。自動震源には、気象庁、防災科研 MOWLAS (Hi-net, F-net, DONET, S-net)、大学等関係機関の波形を利用しました。