



هوش مصنوعی در پایش زلزله: رویکردهای ترکیبی کلاسیک و یادگیری عمیق برای تشخیص خودکار زمین لرزه و فازهای لرزه‌ای

محمد شکری کاوه

توسعه رویکردهای خودکار جهت تشخیص زمین‌لرزه ...

1. مقدمه
2. اهمیت و ضرورت الگوریتم‌های خودکار
3. پیشینه مطالعاتی روش‌های کلاسیک و مبتنی بر یادگیری
4. داده‌ها
5. الگوریتم هیبریدی جدید برای تشخیص خودکار فازبرشی S
6. معرفی هوش مصنوعی، یادگیری ماشین و یادگیری عمیق
7. مدل‌های هیبریدی یادگیری عمیق برای تشخیص رویداد زلزله
8. یک مدل چند منظوره جدید برای تشخیص رویداد و فازهای لرزه‌ای

- یکی از مراحل اصلی و مهم در شبکه‌های لرزه‌نگاری، پردازش اولیه داده‌های فراهم شده از این شبکه‌ها است. پردازش اولیه این داده‌ها شامل:


✓ تشخیص رویداد زلزله در داده‌های

✓ استخراج سیگنال زلزله

✓ تعیین زمان رسید فازهای اصلی

✓ محاسبه بزرگا و پارامترهای کانون

✓ اطلاع‌رسانی در صورت لزوم



- چالش‌های قرائت چشمی/دس

✓ زمان‌بر و پرهزینه بودن


✓ وابستگی به نیروی انسانی و تجربه شخصی تحلیلگران

✓ عدم توافق کارشناسان بر زمان رسید یکسان


✓ تغییرات در انتخاب زمان توسط یک کارشناس در زمان‌های مختلف



گسترش شبکه های




سامانه های هشدار سریع و
سونامی




توسعه شبکه های

منطقه ای و جهانی



پردازش سریع داده های مطالعات
توموگرافی لرزه ای

Seismic tomography



اهمیت و
ضرورت
الگوریتم های
خودکار



Type Method	Representative	Advantage	Disadvantages	Reference
Manual Processing	-	No algorithms required	Low efficiency, poor consistency	
Traditional Method	STA/LTA	Simple, fast	low accuracy, sensitive to SNR	Allen, R. V. (1978)
	Template Matching	Effective for repeated earthquakes	Massively templates needed, inefficient calculation	Haykin, S. (1996)
	Traditional ML	Using specific wave features	Hardware limitations in computations	Chiaruttini, C(1989)
Hybrid Methods	WT-AR	Higher accuracy through method combination	Computational complexity and high resource needs	Karamzadeh, N. (2012), Shokri-Kaveh, M.(2023)
Deep Neural Networks	ConvNetQuake, EQT, PhaseNet	High accuracy High precision High efficiency	Massively labeled seismic data needed	Mousavi, S.M. (2021) Zhu, Q.(2018)

پیشینه مطالعاتی روش‌های کلاسیک و مبتنی بر یادگیری در وظیفه تشخیص زلزله و فازهای لرزه‌ای






داده‌های استفاده شده در این پژوهش

1. 180 رویدادهای محلی و منطقه‌ای با بزرگای بزرگتر از 4 و با فاصله رومرکز سطحی بین 100 تا 1000 کیلومتر است که در بازه زمانی نوامبر 2018 تا نوامبر 2019 توسط دو شبکه لرزه‌نگاری معتبر در ایران ثبت شده‌اند (IRSC و BIN).
2. 50 زمین‌لرزه با بزرگی $M > 3$ از شبکه لرزه‌نگاری KIK-Net ژاپن
3. بخشی از مجموعه داده STEAD
4. یک هفته داده پیوسته از زلزله ملارد (18 دسامبر تا 24 دسامبر 2017)
5. دو هفته داده شبکه موقت اهر-ورزقان در 9 ایستگاه

تبدیل موجک

یک نمونه مصنوعی که حساسیت تبدیل موجک را نسبت به تغییرات دامنه (a)، فرکانس (b) و فاز (c) نشان می‌دهد. ردیف بالا داده‌های مصنوعی را در حوزه زمان نمایش می‌دهد، ردیف وسط ضرایب UDWT را نشان می‌دهد و ردیف پایین پوش مربوط به ضرایب تبدیل موجک را به ترتیب نمایش می‌دهد. تغییرات در حوالی نمونه شماره ۱۰۰۰ رخ داده‌اند.



<https://doi.org/10.1007/s10950-019-09852-z>

ORIGINAL ARTICLE



Automatic P-wave picking using undecimated wavelet transform

Mohammad Shokri Kaveh · Reza Mansouri · Ahmad Keshavarz

Received: 8 December 2018 / Accepted: 4 July 2019
© Springer Nature B.V. 2019

Abstract From the seismologists' point of view, it is extremely important to accurately detect the first P wave arrival time. The P wave arrivals have considerable information about events such as location, magnitude, mechanism, and source parameters. In the classic methods, P wave pickings have been accomplished manually in a visual way. But in the era of information and communication technology, it can be done by computer programs. Seismologists have developed many methods for the picking of the first arrival time of P wave. The wavelet transform is one of the methods to analyze the arrival times and useful for picking up the singularities of any function. Decomposing signals by wavelet transform is a master key to the study of time-frequency varying signals such as earthquake seismograms. This paper presents P phase picking without any prior information using undecimated wavelet transform. For undertaking this study, a simple envelope characteristic function is used for P phase picking. The proposed method is tested on 5 earthquakes recorded by the Fnet network in Japan

that have varying signal-to-noise ratio levels for calibrating. Then the method is applied on 50 earthquakes. The observed results are compared with manual phase picking and standard STA/LTA method. The wavelet base method shows the higher accuracy of phase picking in event detection and time picking, respect to the standard STA/LTA method, when compared to manual picking.

Keywords Wavelet transform · Phase picking · Japan · Arrival time · Signal · Earthquake

1 Introduction

The automatic picking of seismic phases is of great importance in seismic data processing, particularly in hold examples such as the process of locating and tomography. With their continuous activation all around the world, seismic networks, produce a volume of waveforms whose manual processing would require both considerable time and manpower. Human error in detection of the phase, too, may seriously affect future studies. Hence, a faster more efficient and accurate alternative method is required. An alternative method that cannot only reduce the human, finan-

Geophysical Journal International

Geophys. J. Int. (2023) 232, 1393–1407
Advance Access publication 2022 October 12
GJI Seismology<https://doi.org/10.1093/gji/ggac398>

A hybrid method based on undecimated discrete wavelet transform and autoregressive model to S-wave automatic picking

Mohammad Shokri-Kaveh,¹ Gholam Javan-Doloei ,¹ Reza Mansouri ,² Nasim Karamzadeh³ and Ahmad Keshavarz ^{3,4}¹Department of Seismology, International Institute of Earthquake Engineering and Seismology, 1953714515, Tehran, Iran. E-mail: javandoloei@iiees.ac.ir²Department of Geophysics, Persian Gulf University, 7516913817, Bushehr, Iran³Geophysical Institute (GPI), Karlsruhe Institute of Technology (KIT), 76187, Karlsruhe, Germany⁴ICT and Signal Processing Research Group, ICT Research Institute, Faculty of Intelligent Systems Engineering and Data Science, Persian Gulf University, 7516913817, Bushehr, Iran

Accepted 2022 October 10. Received 2022 August 9; in original form 2022 February 6

SUMMARY


Automatic S-wave arrival time estimation is, due to the complex characteristic of most of the S onsets, a topic of ongoing research. Manual as well as automated S-wave picking is more difficult than P-wave picking, as S wave is usually buried in the preceding P-coda. In addition, S-wave splitting, due to possible seismic anisotropy, and the presence of Sp-converted precursors, due to shallow strong velocity discontinuities, increase the complexity of S-wave onset time picking. The goal of this study is to develop an automatic S-wave onset time picking algorithm, using undecimated discrete wavelet transform (UDWT) and autoregressive (AR) model. The novelty of this research is the application of UDWT to define a characteristic function based on the seismogram envelope that leads to accurate S-wave detection. First, an initial arrival time is estimated using the signal envelope. Then S-wave onset is improved with an AR model regarding the fact that a short time after S waves arrival the amplitude is maximized. The robustness of the proposed method under different SNR's has been tested on synthetic seismograms, contaminated with noise. It has also been applied to 180 local and regional events with magnitude greater than 4 and epicentral distance from 100 to 1000 km, recorded by the permanent seismic networks within Iran. We also applied our method to a data set from Japan; the data set contains 30 events with a magnitude range greater than 3. The results of our proposed algorithm are compared with a traditional reference method, novel deep learning methods and manually picked phases. The tested data set contains 1160 manual picks from Iran earthquakes data set and 518 manual picks from Japan earthquakes data set. The results show that the proposed method appears to be promising to replace manual phase picking. The automatic picking algorithm described in this study is applicable in many seismological studies that require S onset detection and picking.

Key words: Time-series analysis; Wavelet transform; Body waves; Earthquake early warning; Seismic noise; Deep Learning.

Kaveh · R. Mansouri (✉) · A. Keshavarz
Persian Gulf University
Bushehr, Iran
s.r.mansouri@pgu.ac.ir




الگوریتم هیبریدی جدید برای تشخیص خودکار فاز برشی S






پیش‌پردازش



مولفه‌های E و N بعد از پیش‌پردازش



طول
سیگنال

حد اکثر سطح تجزیه $K = [\log_2 N]$

$$\tilde{E}(t) = \sum_{k=1}^k \tilde{E}_k^D(t) + \tilde{E}_k^A(t)$$

$$\tilde{N}(t) = \sum_{k=1}^k \tilde{N}_k^D(t) + \tilde{N}_k^A(t)$$

ضرایب تبدیل موجک بدست آمده برای مولفه E و مولفه N.




تخمین اولیه از
زمان رسید فاز S

$$tS_e = \left\{ t \mid \frac{d\hat{E}_e^D(t)}{dt} = 0, t = \arg \min_{t'} |t' - t_e^{\max}| \right\}$$

$$tS_n = \left\{ t \mid \frac{d\hat{N}_n^D(t)}{dt} = 0, t = \arg \min_{t'} |t' - t_n^{\max}| \right\}$$

پوش مربوط به ضرائب تبدیل موجک ، خط چین افقی نصف
ماکزیمم پیک را نشان می دهد.





تخمین پوش برای دو مقدار مختلف m : (a) با مقدار کوچک
(b) با مقدار بزرگ





تخمین اولیه از زمان رسید فاز S



خط نقطه چین عمودی (آبی) ماکزیمم پیک را نشان می دهد و خط عمودی خط - نقطه چین (سبز) اولین مینیمم محلی معادل با نصف ماکزیمم را نشان می دهد. خط کوتاه افقی ضخیم (قرمز) پنجره تعیین شده برای محاسبه واریانس از شکل موج اصلی برای

واریانس محاسبه شده مربوط به مولفه های E و N. خط کوتاه افقی قرمز رنگ طول پنجره زمانی در اطراف زمان رسید موج S می باشد. مولفه ای که دارای واریانس بیشتری باشد به عنوان مولفه غالب برای شناسایی زمان رسید موج S




تخمین نهایی از زمان رسید فاز S

$$y(t_n) = \sum_{i=1}^Q a_i y(t_{n-i}) + v(t_n) \quad t_n = t-w, \dots, t+w$$

$$C(t_n) = 100 \times \left(1 - \frac{\|y_{t_n}(t) - \hat{y}_{t_n}(t)\|}{\|y_{t_n}(t) - \bar{y}_{t_n}(t)\|} \right) \quad t_n = tS-w, \dots, tS+w$$

$$tS_f = \arg \min_{t_n} C(t_n) \quad t_n = tS-w, \dots, tS+w$$




مدل AR اعمال شده بر روی سیگنال (خط آبی). خط سبز عمودی اولین ماکزیمم محلی را نشان می دهد، و خط عمودی خط -نقطه چین قرائت دستی و خط عمودی نقطه چین شناسایی خودکار را نشان می دهد. مقیاس سمت چپ مربوط به دامنه سیگنال و

مقیاس سمت راست مربوط به دامنه مدل AR می باشد.







ارزیابی الگوریتم بر روی داده‌های واقعی



Comparisons of pickers proposed algorithm and the Karamzadeh *et al.* (2012) algorithm (Reference method) for **180 events**, with **1160 available manual S-wave readings**.

	Manual	Proposed_Method	Ref_Method
Picks (%)	100	99.83	98.79
Correct picks (%)	100	94.91	85.84
Mean $\pm$ Std (s)	-	0.98 $\pm$ 1.04	0.33 $\pm$ 1.99
ERR < 1 s (%)	-	41.54	42.23
ERR < 2 s (%)	-	80.74	61.23
FRR < 3 s (%)	-	86.10	69.78





(a) Our method and (b) Reference method.

توزیع مکانی و عمقی رویدادهای با بزرگی $ML \geq 4$ که در بازه زمانی نوامبر 2018 تا نوامبر 2019 رخ داده‌اند، دایره‌ها مکان رویدادهای را نشان می‌دهند، و مثلث‌های سیاه و مربع‌های سیاه به ترتیب ایستگاه‌های لرزه‌نگاری مرکز لرزه‌نگاری ایران و شبکه لرزه‌نگاری به‌بناد ملی ایران را نشان می‌دهند.



ارزیابی الگوریتم بر روی داده‌های واقعی



سیگنال مربوط به ایستگاه QOM با فاصله 250 کیلومتر و نسبت سیگنال به نوفه نسبتاً بالا. (b) نسخه بزرگنمایی شده از سیگنال اصلی که نشان می‌دهد شناسایی خودکار با روش پیشنهادی (خط نقطه‌دار) به شناسایی دستی (نقطه‌دار-چین) نزدیکتر است، در حالی که شناسایی خودکار با روش مرجع (خط چین) دورتر از شناسایی دستی است.

ایستگاه AZR با نسبت سیگنال به نوفه با فاصله رومرکز 313 کیلومتر.







مقایسه الگوریتم با روشهای یادگیری عمیق و داده‌های مناطق دیگر ...

Comparison of the statistics of time residuals of our method and EQT model with manual picking on the Japan data.

Methods	No Pick	Picked (%)	Correct picks (%)	Mean $\pm$ Std (s)
EQT	165	68.15	67.37	5.05 $\pm$ 1.5
Our Method	31	94.01	93.82	0.29 $\pm$ 0.89



S-pick residuals obtained by the EQT model and proposed method on the Japan data: (a)EQT; (b) proposed method.


50 رویداد لرزه‌ای با
بزرگی بیش از 3، در بازه
زمانی 10/11/2018 تا
27/02/2019 از شبکه KiK-
net ژاپن.



مقایسه الگوریتم با روش های یادگیری عمیق و داده های مناطق دیگر ...

The statistics of time residuals of the EQT model on the Iranian data set.

	No Pick	Picked (%)	Correct Pick	Mean $\pm$ Std (s)
EQT	395	68.88	65.82	5.6 $\pm$ 2.5




Histograms of S-pick residuals obtained by the EQT model on the Iran data.



هوش مصنوعی



هوش ماشین = قابلیت ادراک و یادگیری ماشین

هدف: شبیه سازی و درک رفتار انسان







یادگیری ماشین






یادگیری عمیق





پیاده سازی و آموزش مدل



1. آماده سازی داده های آموزش

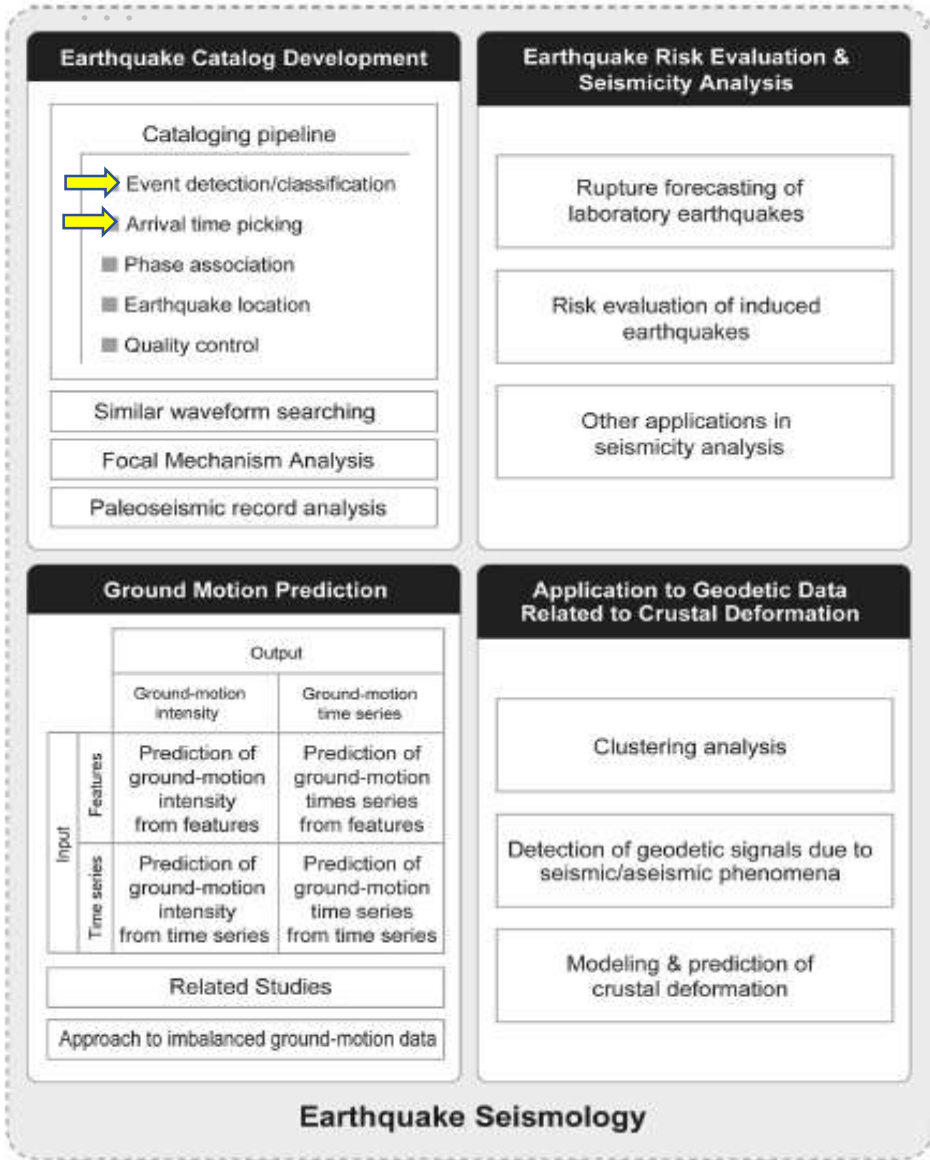
2. انتخاب معماری مناسب شبکه

3. الگوریتم آموزش و بهینه سازی

4. روش های بهبود آموزش



Kubo (2024)




زلزله‌شناسی و یادگیری عمیق

دستاورها

چالش‌ها

چشم اندازهای آینده




Mousavi & Beroza (2022)





مدل‌های هیبریدی یادگیری عمیق برای تشخیص رویداد زلزله








معماری مدل پیشنهادی.



مجموعه داده STEAD


1.2 M Labeled Waveform. 450 k Earthquakes. 19,000 Hours of Data.

2613 Stations.



Mousavi et al (2019)





داده ها و

تنظیمات آموزش

Framework = Pytorch

System= RAM: 128G, CPU: Xeon 3.2 GHz and GPU: Tesla K80×4


Optimizer = AdamW

Loss function= BCE


Learning rate = 10^{-4}

Bach size= 64


Epoch=75



تقسیم بندی مجموعه داده مورد استفاده در این بخش.



Accuracy and loss curves for training and validation datasets





Performance metrics

		True class	
Predicted class	Actual class	TP (True Positive)	FP (False Positive)
	Actual class	FN (False Negative)	TN (True Negative)

Precision P

$$P = \frac{T_p}{T_p + F_p}$$

Recall R

$$R = \frac{T_p}{T_p + F_n}$$

Accuracy A

$$A = \frac{T_p + T_n}{T_p + T_n + F_p + F_n}$$

F1-score F_1

$$F_1 = \frac{2PR}{P + R}$$




ارزیابی عملکرد مدل-های پیشنهادی

Performance metrics for different models on the **validation** set.


Models	PRE	REC	F1	ACC
LCNN+Self-attention	0.99 68	0.99 58	0.99 62	0.99 85
LCNN+CBAM	0.9955	0.9959	0.9956	0.9982
LCNN+AG	0.9953	0.9946	0.9949	0.9978
LCNN +SEblock	0.9949	0.9947	0.9947	0.9973
LCNN	0.9951	0.9937	0.9943	0.9969

The proposed models' performance on the **test** dataset compared with that of the pretrained models (highlighted in yellow) and STA/LTA detector.

Models	PRE	REC	F1	ACC
LCNN+Self-attention	0.99 64	0.99 61	0.99 62	0.99 83
LCNN+CBAM	0.9957	0.9950	0.9953	0.9980
LCNN+AG	0.9949	0.9952	0.9950	0.9977
LCNN+ SEblock	0.9948	0.9951	0.9949	0.9975
LCNN	0.9931	0.9954	0.9942	0.9956
OBS-transformer	0.9883	0.9545	0.9711	0.9583
CRED	0.9395	0.9000	0.9198	0.8626
PickBlue	0.6998	0.9927	0.8209	0.9323
STA/ LTA	0.6485	0.9807	0.7809	0.6528




انتخاب موجک مادر بهینه




سیگنال‌های مشخصه موجک‌های مادر

The most important properties of the Mother wavelets are [Sang et al. \(2016\)](#):

- ☐ The wavelet should have a progressive and linear phase.
- ☐ The wavelet should exhibit good localization both in the time and frequency domains.
- ☐ The wavelet should be adapted to the trade-off between time and scale resolutions.
- ☐ The wavelet should also meet the orthogonal condition.



انتخاب موجک مادر بهینه





Performance of models by different mother wavelets on data test.

Mother Wavelet	Models	PRE (%)	REC (%)	F1 (%)	ACC (%)
Db10	LCNN+Self-attention	99.64	99.61	99.62	99.83
	LCNN+CBAM	99.57	99.50	99.53	99.80
	LCNN+GA	99.49	99.52	99.50	99.79
	LCNN+SEblock	99.51	99.48	99.49	99.78
	LCNN	99.31	99.54	99.42	99.75
Db4	LCNN+Self-attention	99.61	99.57	99.59	99.77
	LCNN+CBAM	99.46	99.47	99.46	99.79
	LCNN+GA	99.45	99.49	99.46	99.78
	LCNN+SEblock	99.47	99.50	99.48	99.75
	LCNN	99.42	99.39	99.44	99.67
Sym7	LCNN+Self-attention	99.61	99.61	99.61	99.79
	LCNN+CBAM	99.49	99.58	99.53	99.77
	LCNN+GA	99.49	99.51	99.49	99.77
	LCNN+SEblock	99.42	99.49	99.45	99.71
	LCNN	99.45	99.50	99.47	99.72
Coif4	LCNN+Self-attention	99.58	99.54	99.56	99.76
	LCNN+CBAM	99.49	99.48	99.48	99.73
	LCNN+GA	99.47	99.49	99.48	99.74
	LCNN+SEblock	99.41	99.48	99.44	99.7
	LCNN	99.72	99.05	99.88	99.88




عملکرد مدل‌ها بر روی



داده‌های پیوسته

- زلزله ملارد، 18-24 دسامبر 2017 در ایستگاه CHTH
- 30 درصد همپوشانی
- گزارش کاتالوگ BIN : 19 رویداد
- با بزرگای بیش از 3
- تمامی پیش‌بینی شدند


نمونه‌هایی از شکل موج‌های زلزله‌های شناسایی‌شده توسط مدل‌ها بر روی داده پیوسته از تاریخ 21 دسامبر 2017 در ایستگاه CHTH.

Model	Number of Signal	False Positives
LCNN+Self-attention	769	9
LCNN+CBAM	758	8
LCNN+ AG	728	10
LCNN+SEblock	744	11
LCNN	739	15






رمزنگار E)
(ncoder




رمزگشا (Dec
(oder





داده‌ها ، برچسب‌گذاری و تنظیمات آموزش

From P arrival to the S arrival + 1.4 × (S – P time)



600k data from STEAD

100k Noise

500k Earthquake

Training = 70% (420k)
Validation = 20% (120k)
Test = 10% (60k)

Framework = Pytorch

System= RAM: 64G, CPU: Intel Core i9 and GPU: NVIDIA GeForce RTX 4090

Optimizer = Adam

Loss function= BCEWithLogits + L1
 $(L_{total} = \alpha.BCE_P + \beta.BCE_S + \gamma.BCE_E + \delta.L1_P + \epsilon.L1_S + \rho.L1_E)$

Learning rate = 10^{-4} (ReduceLROnPlateau)

Bach size= 8

Epoch=200







ارزیابی عملکرد مدل

$$\text{Precision} = \frac{TP}{TP + FP} \quad \text{Recall} = \frac{TP}{TP + FN}$$


$$\text{F1-Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

Pearson coefficient = $\rho_{x,y} = \frac{cov(x,y)}{\sqrt{\sigma_x^2 * \sigma_y^2}}$

Thr = 0.7



ارزیابی عملکرد مدل



عملکرد مدل پیشنهادی در مجموعه‌ی اعتبارسنجی برای سه وظیفه‌ی تشخیص رویداد، برداشت فاز P و برداشت فاز S.

Task	Precision	Recall	F1
Detector	1	0.9999	0.9999
P_picker	0.9947	1	0.9973
S_picker	0.9827	1	0.9913




ارزیابی

عملکرد مدل

مقایسه عملکرد مدل با مدل‌های از پیش آموزش دیده و روش AR picker در Obspy بر روی مجموعه داده تست.


Earthquake Detection	Precision	Recall	F1	Dataset	Ref.
Proposed model	1	0.9999	0.9999	Test Dataset (60k)	This study
PickBlue	0.8177	0.7645	0.7902	Test Dataset (60k)	Bornstein et al (2024)
OBSTransformer	0.8196	0.75680	0.7869	Test Dataset (60k)	Niksejel & Zhang (2024)
EQT	1	1	1	STEAD	Mousavi et al (2020)
P_phase Identification					
Proposed model	0.9950	1	0.9975	Test Dataset (60k)	
PickBlue	0.9834	0.9896	0.9865	Test Dataset (60k)	
OBSTransformer	0.9669	0.9803	0.9735	Test Dataset (60k)	
EQT	0.9900	0.9900	0.9900	STEAD	
AR picker	0.8854	0.8855	0.8855	Test Dataset (60k)	Obspy
S_phase Identification					
Proposed model	0.9813	1	0.9906	Test Dataset (60k)	
PickBlue	0.9834	0.9881	0.9857	Test Dataset (60k)	
OBSTransformer	0.9669	0.9796	0.9732	Test Dataset (60k)	
EQT	0.9900	0.9600	0.9800	STEAD	
AR picker	0.7830	0.7831	0.7831	Test Dataset (60k)	







ارزیابی عملکرد مدل

$$T_{diff} = T_{label} - T_{pred}$$






ارزیابی عملکرد مدل بر روی داده های شبکه موقت




تقسیم بندی داده ها با استفاده از روش 5-Fold برای مجموعه داده آموزشی و آزمون.



نمودار متوسط خطای آموزشی (آبی) و اعتبارسنجی (قرمز) مدل در روش ۵-فولد طی ۱۰۰ دوره آموزشی که همگرایی مناسب مدل و نبود بیشبرازش را تأیید می کند.

ارزیابی عملکرد مدل بر روی داده‌های شبکه موقت




روند تابع خطای آموزش و اعتبارسنجی برای هر فولد بصورت جداگانه که همگرایی مدل و نبود بیش‌برازش را در هر فولد از روش ۵- فولد نشان می‌دهد.



نتایج ارزیابی عملکرد مدل با روش اعتبارسنجی متقابل k-fold بر روی مجموعه داده شبکه موقت بر اساس نمره F1.

	P_picke	S_picke	Detecto
	r	r	r
F1-	0.9629	0.8813	0.9719



ارزیابی عملکرد مدل بر روی داده های شبکه موقت



JGR Solid Earth

RESEARCH ARTICLE
10.1029/2021JB023499

Special Section:
Machine learning for Solid Earth observation, modeling and understanding

James Münchmeyer and Jack Woollam contributed equally.

Key Points:


- We conducted a large scale benchmark of machine learning pickers using six models and eight datasets
- Real overall performance is observed

Which Picker Fits My Data? A Quantitative Evaluation of Deep Learning Based Seismic Pickers


James Münchmeyer^{1,2}, Jack Woollam³, Andreas Riethbrock³, Frederik Tilmann^{1,4}, Dietrich Lange⁵, Thomas Bornstein¹, Tobias Diehl⁶, Carlo Giunchi⁷, Florian Haslinger⁶, Dario Jozinovic^{4,9}, Alberto Michelini⁸, Joachim Saul¹, and Hugo Soto¹

¹Deutsches GeoForschungsZentrum GFZ, Potsdam, Germany, ²Institut für Informatik, Humboldt-Universität zu Berlin, Berlin, Germany, ³Geophysical Institute (GPI), Karlsruhe Institute of Technology, Karlsruhe, Germany, ⁴Institut für geologische Wissenschaften, Freie Universität Berlin, Berlin, Germany, ⁵GEOMAR Helmholtz Centre for Ocean Research Kiel, Kiel, Germany, ⁶Swiss Seismological Service, ETH Zurich, Zurich, Switzerland, ⁷Istituto Nazionale di Geofisica e Vulcanologia, Sezione di Pisa, Pisa, Italy, ⁸Istituto Nazionale di Geofisica e Vulcanologia, Roma, Italy, ⁹Università degli Studi Roma Tre, Rome, Italy






A sample of event detection and Seismic phases arrival time







A sample of event detection and Seismic phases arrival time







A sample of event detection and Seismic phases arrival time






A sample of event detection and Seismic phases arrival time







A sample of event detection and Seismic phases arrival time





A sample of event detection and Seismic phases arrival time






نتایج و دستاویزها

1. طراحی الگوریتمی مبتنی بر تبدیل موجک و مدل AR برای تشخیص زمان ورود موج S


الگوریتم خودکاری برای تشخیص زمان ورود موج S طراحی شد، این الگوریتم از تبدیل موجک برای تجزیه سیگنال به مؤلفه‌های زمان-فرکانس و ایجاد تابع مشخصه مبتنی بر پوش سیگنال استفاده کرد، که در حضور نوفه کارایی بالایی دارد. همچنین، مدل اتورگرسیو با مدل‌سازی آماری رفتار سیگنال، زمان ورود موج S را با دقت برآورد کرد. فرآیند تشخیص شامل تخمین اولیه زمان ورود با پوش ضرایب موجک و بهبود آن با مدل AR بود. الگوریتم روی داده‌های مصنوعی با نسبت‌های مختلف سیگنال به نوفه و داده‌های واقعی (180 رویداد با بزرگی بیش از 4 در ایران و 30 رویداد با بزرگی بیش از 3 در ژاپن) آزمایش شد. نتایج نشان داد این روش در مقایسه با تکنیک‌های سنتی، یادگیری

عمیق دقت بالاتری دارد و برای تحلیل سریع و دقیق مناسب است.



2. مدل‌های هیبریدی یادگیری عمیق برای تشخیص رویداد زلزله

پنج مدل ترکیبی با ادغام شبکه‌های هم‌میختی سبک‌وزن و مکانیزم‌های توجه پیشرفته برای طبقه‌بندی سیگنال‌های زلزله طراحی شدند. این مدل‌ها از یک مرحله پیش‌پردازش با استفاده از تبدیل موجک برای استخراج ویژگی‌های زمان-فرکانس سیگنال‌های لرزه‌ای استفاده کردند، با انتخاب موجک مادر متناسب با سیگنال‌های زلزله. مکانیزم‌های توجه شامل Self-Attention، CBAM، SE-Block و Attention Gate بودند که الگوهای پیچیده را شناسایی، دقت را افزایش، کارایی محاسباتی را بهبود دادند. این مدل‌ها با شبکه‌های سبک‌وزن ترکیب شدند تا کارایی بالا با زمان محاسباتی کم ارائه دهند. ارزیابی روی مجموعه داده STAED و داده‌های زلزله ملارد 1396 نشان داد مدل در مقایسه با دیگر مدل‌ها و در داده‌های پیوسته عملکرد خوبی ارائه داد. تعمیم‌پذیری بالای این مدل‌ها، کاربرد آن‌ها را در پایش لرزه‌ای عملیاتی تأیید کرد.



3. یک مدل چند منظوره برای تشخیص همزمان رویداد زمین لرزه و

فازهای زمین لرزه D R C

یک مدل چندوظیفه‌ای نوین با الهام از چارچوب EQT، شامل رمزگذار عمیق و سه رمزگشای مستقل، با استفاده از هم‌امیخت‌های دوبعدی، شبکه‌های LSTM و BiLSTM، معماری شبکه‌در شبکه، اتصالات باقی‌مانده، ترانسفورمرها و لایه‌های خود-توجه طراحی شد.

ورودی این مدل اسکالوگرام‌های تبدیل موجک که بعنوان یک مرحله پیش‌پردازش ویژگی‌های زمانی-مکانی سیگنال‌های لرزه‌ای استخراج شده‌اند. رمزگذار نمایشی سطح بالا تولید کرد و رمزگشاها سه توالی احتمال برای تشخیص سیگنال زلزله و فازهای P و S ارائه دادند. با تکنیک‌های منظم‌سازی و کاهش نمونه‌برداری، مدل روی مجموعه داده STEAD (600 هزار داده) و داده‌های اهر-ورزقان (به مدت دو هفته (تقریباً 5 هزار داده)) آزمایش شد و دقت بالایی در شناسایی رویدادها و فازها نشان داد. این چارچوب با یکپارچه‌سازی تکنیک‌های پیشرفته مانند تبدیل

موجک، مدل‌های یادگیری عمیق، دقت و کارایی ارتقا داد. این پژوهش با پر کردن شکاف میان روش‌های سنتی و



با تشکر از
توجه شما