

ДОЛГОСРОЧНЫЙ ПРОГНОЗ ЭЛЬ-НИНЬО С УЧЕТОМ ВАРИАЦИЙ СОЛНЕЧНОЙ АКТИВНОСТИ

Волобуев Д.М., Макаренко Н.Г., Князева И.С.

Главная (Пулковская) астрономическая обсерватория РАН, Санкт-Петербург, Россия

LONG-TERM FORECAST OF EL NIÑO TAKING INTO ACCOUNT VARIATIONS IN SOLAR ACTIVITY

Volobuev D.M., Makarenko N.G., Knyazeva I.S.

Main Astronomical (Pulkovo) Observatory RAS, St. Petersburg, Russia

<https://doi.org/10.31725/0552-5829-2023-51-54>

The El Niño phenomenon, as a consequence of changes in the ocean circulation regime, has a significant impact on the global climate and related economic activities. According to our hypothesis, in addition to internal climatic factors, the ocean circulation regime can be controlled by small changes in the total solar irradiance (TSI) occurring in the 11-year cycle of solar activity. In that case, a positive feedback with an amplification factor of about 10 is possible in the near-equatorial regions. In this paper, we forecast monthly averages of the El Niño Nino3.4 index both without and with TSI variability. For the prediction, we train a deep learning recurrent neural network (LSTM) on the Nino3,4 only and with adding TSI as an additional predictor. As a result, we find that training error of Nino3,4 decreases when TSI is added as a predictor. Our result emphasizes the promising potential of using TSI as one of the predictors in the construction of state-of-the-art nonlinear predictive models of global climate.

Введение

Явление Эль-Ниньо, связанное с изменениями режима атмосферной и водной циркуляции в Тихом океане – одно из основных глобальных нелинейных колебаний, оказывающее воздействие на всю климатическую систему Земли. Общеизвестно, что эволюция Эль-Ниньо объясняется нелинейными автоколебаниями. В первом приближении такие колебания могут быть описаны системой обыкновенных дифференциальных уравнений второго порядка [1]. Такое описание, однако, не полно, и не обобщается до предсказания. Следующим шагом является добавление в правую часть вынуждающей силы, которой может являться инсоляция, при наличии механизмов усиления [2]. Ранее, в рамках этого подхода мы находили статистическое подтверждение гипотезы о наличии управляющего воздействия на индекс Эль-Ниньо (Nino3,4) со стороны полного потока излучения Солнца (TSI) методом условных дисперсий [3]. Это позволяет надеяться на возможность прогнозирования индексов Nino3,4 и TSI, как связанных переменных сложной динамической системы. В рамках этого подхода, в данной работе мы пытаемся ответить на вопрос: можно ли улучшить прогноз индекса Nino3,4, используя индекс TSI как дополнительный предиктор ре-

ализованный рекуррентной нейронной сети типа «долговременная краткосрочная память» (LSTM) и глубоким обучением.

Исходные данные

Мы использовали следующие среднемесячные временные ряды (см. рис. 1) эмпирический климатический индекс Nino3.4 [4] и 2) климатическую реконструкцию TSI [5]. Индекс Nino 3.4 основан на данных о температуре поверхностных вод в экваториальной зоне Тихого океана (5°N – 5°S , 120°W – 170°W) и отражает вариации локального климата в океане, в частности, явление Эль-Ниньо. Реконструкция TSI Naval Research Laboratory (NRLTSI2) была получена путем продолжения в прошлое данных космических наблюдений с использованием модельной оценки TSI по солнечным пятнам и факелам [6].




Рис. 1. Временные ряды индексов TSI и Эль-Ниньо.

Методика

В 1997 г. Зепп Хохрайтер и Юрген Шмидхубер предложили модификацию рекуррентных нейронных сетей, которая могла запоминать контекст [7]. Так появились сети LSTM (Long Short-Term Memory) – разработанные специально для работы с временными последовательностями, которые обладают способностью моделировать долгосрочные зависимости в данных [8]. В LSTM есть специальное клеточное состояние (Cell state), которое проходит через всю сеть и может сохранять информацию на протяжении многих временных шагов. Это клеточное состояние обновляется и моди-

фицируется в зависимости от входных данных и внутренних обратных связей. Для этого в LSTM используются механизмы «ворот», такие как ворота забывания (forget gate), ворота обновления (update gate) и ворота вывода (output gate), чтобы решать, какая информация должна быть сохранена в клеточном состоянии и передана на следующий временной шаг. Эти ворота позволяют сети сохранять важные информационные аспекты и забывать ненужные. Поэтому LSTM может поддерживать длинные цепи временных шагов, учитывая таким образом информацию с прошлых временных шагов, при прогнозировании будущих значений. Это делает LSTM подходящим инструментом для моделирования долгосрочных зависимостей [8].




Рис. 2. Изменение ошибки в процессе обучение сети LSTM для прогноза индекса Nino3,4. Черные кривые — на основе только Nino3,4; Серые кривые — совместное обучение Nino3,4 и TSI.




Рис. 3. Тестовый прогноз Nino3,4 для обучения нейронной сети LSTM на интервале до середины 2016 года. Пунктир — при обучении использовались только данные Nino3,4. Серые кривые — при обучении использовались данные как Nino3,4, так и TSI. Жирной черной кривой показаны истинные значения Nino3,4.

С небольшими модификациями архитектура LSTM была применена для прогнозирования числа пятен на Солнце [9] и для предсказания различных индексов поверхностной температуры моря, включая индекс Эль-Ниньо [10]. Эти сети оказались лучшими и при прогнозировании потока солнечного излучения [11]. В данной работе мы обучали сеть LSTM в среде MatLab R2021b; сеть имела 256 скрытых слоев и начальную скорость обучения 0.01. Обучение производилось как на индексе Nino3,4 так и на паре индексов Nino3,4 и TSI (рис. 1).

Результаты

Минимизация ошибки при обучении сети, начиналась со случайных начальных весов, и приводило каждый раз к различным результатам как

при обучении (рис. 2), так и при прогнозе (рис. 3). Тем не менее, обучение всегда происходит быстрее и лучше (относительно ошибки), если используются оба предиктора, а не только сам индекс Nino3,4 (рис. 2). Качество прогнозов на 4-х летнем тестовом интервале (рис. 3) для этих двух случаев статистически не различимо, коэффициент корреляции между истинными и прогнозируемыми значениями меняется в диапазоне (0.5–0.9), со средним 0.7. Это превосходит современный уровень точности прогнозов Эль-Ниньо, где коэффициент корреляции падает ниже 0.5 при прогнозировании далее чем на год [12]. Поскольку истинные значения в этом варианте не использовались для дообучения сети, точность прогноза падает с ростом его длительности. В первые два года прогноз в среднем визуально несколько улучшается при использовании TSI (рис. 3).

Литература

1. *Jin, F.F.* An equatorial ocean recharge paradigm for ENSO. Part I: Conceptual model // *Journal of the atmospheric sciences*, 1997, 54(7), pp.811-829.
2. *White W.B., Liu Z.* Non-linear alignment of El Nino to the 11-yr solar cycle // *Geophysical Research Letters*. 2008. T. 35. №. 19.
3. *Skakun, A.A. and Volobuev, D.M.* Causal Relationships between Climate Indices and the Solar Constant over the Last 100 Years // *Geomagnetism and Aeronomy*, 2022, 62(8), pp.1123-1127.
4. NINO 3.4 NOAA https://psl.noaa.gov/gcos_wgsp/Timeseries/Data/nino34.long.data
5. TSI http://lasp.colorado.edu/lisird/data/nrl2_tsi_P1M/
6. *Coddington O. et al.* A solar irradiance climate data record // *Bulletin of the American Meteorological Society*. 2016. T. 97. №. 7. C. 1265-1282.
7. *Hochreiter, S., and J. Schmidhuber.* Long short-term memory // *Neural computation*, 1997, Vol. 9, Number 8, pp.1735–1780.
8. *Staudemeyer, R.C., & Morris, E.R.* Understanding LSTM – a tutorial into Long Short-Term Memory Recurrent Neural Networks, 2019 (arXiv:1909.09586). arXiv. <https://doi.org/10.48550/arXiv.1909.09586>
9. *Lee, T.* EMD and LSTM Hybrid Deep Learning Model for Predicting Sunspot Number Time Series with a Cyclic Pattern // *Solar Physics*, 2020, 295(6), 82.
10. *Xiaoqun, C., Yanan, G., Bainian, L., et al.* ENSO prediction based on Long Short-Term Memory (LSTM). IOP Conference Series: Materials Science and Engineering, 2020, 799(1), 012035.
11. *Wentz, V.H., Maciel, J.N., Gimenez Ledesma, J.J., & Ando Junior, O.H.* Solar Irradiance Forecasting to Short-Term PV Power: Accuracy Comparison of ANN and LSTM Models // *Energies*, 2022, 15(7), Article 7. <https://doi.org/10.3390/en15072457>
12. *Kim, J., Kwon, M., Kim, S.D., et al.* Spatiotemporal neural network with attention mechanism for El Niño forecasts // *Scientific Reports*, 2022, 12(1), p.7204.