

УДК 551.5

DOI: 10.21685/2307-9150-2017-3-7

А. А. Николаев, Н. В. Исмагилов

ПРИМЕНЕНИЕ НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ ДЛЯ ВЫЧИСЛЕНИЯ ПОТОКОВ СУММАРНОЙ СОЛНЕЧНОЙ РАДИАЦИИ

Аннотация.

Актуальность и цели. Солнечная радиация является основным фактором для многих физических, химических и биологических процессов на земной поверхности. Однако данные о потоках солнечной радиации не всегда доступны по целому ряду причин: отсутствие метеостанций или проведения актинометрических наблюдений на них. Таким образом, актуальным становится вопрос вычисления потоков солнечной радиации. Основной целью данного исследования является обзор искусственных нейронных сетей (ИНС), с целью выявления подходящих моделей для вычисления солнечного излучения и выявления пробелов в исследованиях.

Материалы и методы. В качестве исходного материала использовались данные метеорологической обсерватории Казанского федерального университета.

Результаты. Исследование литературных источников показывает, что искусственные нейросетевые методы прогнозирования солнечной радиации более точны по сравнению с обычными методами. Разработаны десять моделей с различными входными параметрами. Выявлены наиболее лучшие из них.

Выводы. Результаты свидетельствуют, что использование нейросетевых моделей для вычисления потоков солнечной радиации является перспективным направлением исследований. Полученные модели позволяют рассчитывать характеристики солнечной радиации с использованием метеорологических параметров.

Ключевые слова: нейронные сети, суммарная радиация, прогнозирование.

A. A. Nikolaev, N. V. Ismagilov

APPLICATION OF NEURAL NETWORK TECHNOLOGIES TO CALCULATE TOTAL SOLAR RADIATION FLUXES

Abstract.

Background. Solar radiation is the main factor in many physical, chemical and biological processes on the earth's surface. However, solar flux data are not always available for a variety of reasons, e.g. a lack of meteorological stations or solar radiation observations on them. Thus, calculation of solar radiation fluxes appears to be a topical question. The main purpose of this study is to review artificial neural networks (ANN), in order to identify suitable models for calculation of solar radiation and to reveal research gaps.

Materials and methods. The data from the Meteorological Observatory of Kazan Federal University were taken as the initial research material.

Results. Studying of literary resources indicates that artificial neural network methods of solar radiation prediction are more accurate compared to conventional methods. Ten models with different input parameters have been developed and the best of them have been revealed.

Conclusions. The results indicate that the use of neural network models for calculation of solar radiation fluxes is a promising area of research. These models allow us to calculate solar radiation characteristics with the use of meteorological parameters.

Key words: neural networks, total radiation, prediction.

Введение

Солнечная радиация занимает одно из лидирующих положений среди возобновляемых источников энергии. Суммарный поток энергии солнечного излучения, поступающий на поверхность Земли, во много раз превышает мощность действующих в мире энергоустановок, а располагаемые ресурсы солнечной энергии на территориях всех стран, в том числе расположенных в высоких широтах, существенно превышают их энергетические потребности на обозримую перспективу [1].

Для многих районов земного шара данные о радиационном режиме полностью отсутствуют вследствие редкой актинометрической сети. Расстояния между ближайшими станциями актинометрической сети обычно измеряют сотнями, а иногда и тысячами километров [2].

В связи с этим возникает необходимость получения требуемых данных о радиационном режиме с помощью расчетных методов. Применение этих методов оказывается возможным благодаря тому, что основные характеристики солнечного режима связаны как между собой, так и с важнейшими метеорологическими характеристиками. Существование таких зависимостей позволяет рассчитывать большую часть отдельных характеристик радиационного режима или их совокупность по метеорологическим данным и некоторому минимальному количеству актинометрических данных [3].

Целью такого моделирования является расчет зависимости сумм солнечной радиации, приходящей на земную поверхность, от географической широты места, метеорологических факторов, дня года, времени суток и угла наклона поверхности. Широкое применение для этих целей нашли модели, основанные на использовании искусственных нейронных сетей.

Искусственные нейронные сети и их использование для расчетов характеристик солнечной радиации. Обзор проблемы

Искусственные нейронные сети (ИНС) – это мощный метод численного моделирования, позволяющий воспроизводить чрезвычайно сложные зависимости. Нейронные сети нелинейны по своей природе [4]. Особенностью таких моделей является то, что зависимость между входом и выходом находится в процессе обучения сети.

В задачах регрессии целью является оценка числовой (принимающей непрерывный диапазон значений) выходной переменной по значениям входных переменных. В ИНС задачи регрессии можно решать с помощью сетей

следующих типов: многослойный персептрон, радиальная базисная функция, обобщенно-регрессионная сеть и линейная сеть. При этом выходные данные должны иметь стандартный числовой (не номинальный) тип [4].

Наиболее распространенная архитектура сети – многослойный персептрон. Каждый элемент такой сети строит взвешенную сумму своих входов с поправкой в виде слагаемого и затем пропускает эту величину активации через передаточную функцию, и таким образом получается выходное значение этого элемента. Элементы организованы в послойную топологию с прямой передачей сигнала. Такую сеть легко можно интерпретировать как модель вход-выход, в которой веса и пороговые значения являются свободными параметрами модели. Сеть может моделировать функцию практически любой степени сложности, причем число слоев и число элементов в каждом слое определяют сложность функции [4].

Количество входных и выходных элементов определяется условиями задачи. После того, как определено число слоев и число элементов в каждом из них, нужно найти значения для весов и порогов сети, которые бы минимизировали ошибку прогноза, выдаваемого сетью. Для этого служат алгоритмы обучения. С использованием собранных исторических данных веса и пороговые значения автоматически корректируются с целью минимизировать эту ошибку. Этот процесс представляет собой подгонку модели, которая реализуется сетью, к имеющимся обучающим данным. Ошибка для конкретной конфигурации сети определяется путем прогона через сеть всех имеющихся наблюдений и сравнения реально выдаваемых выходных значений с целевыми значениями. Все такие разности суммируются в функцию ошибок, значение которой и есть ошибка сети. В качестве функции ошибок чаще всего берется сумма квадратов ошибок.

Использование искусственных нейронных сетей оказывается эффективным инструментом при прогнозировании, позволяющем использовать в качестве предикторов параметры, которые не связаны между собой.

Для изучения режима солнечной радиации требуются долгопериодные ряды наблюдений в близлежащих пунктах и использование эмпирических, полуэмпирических, физических, нейронных сетей, вавелетов, фрактального анализа и других технологий [5]. Существует целый ряд работ, посвященный эмпирическим моделям расчетов солнечной радиации на горизонтальную поверхность, основанных на формуле Ангстрема [6].

Метеорологические и климатологические параметры являются наиболее важными факторами для определения количества солнечной радиации в различных регионах, где нет актинометрических наблюдений, и используются для вычислений с помощью ИНС потоков солнечной радиации [5, 6].

С целью выявления метеорологических и климатологических параметров используемых на входе нейронных сетей для вычисления потоков солнечной радиации рассмотрим ряд исследований в данной области.

Авторы работы [7] использовали температуру воздуха, порядковый номер дня в году и относительную влажность как входные данные нейронных сетей для расчета дневных значений солнечной радиации.

В работе [8] в качестве входных данных модели использовались географические координаты пунктов наблюдения, суммарная радиация при ясном небе, количество облачности, содержание водяного пара и озона.

А. Коджа и другие [9] на входе своей модели использовали широту, долготу и высоту места, среднюю температуру воздуха, количество облачности, скорость ветра и продолжительность солнечного сияния.

Т. С. Хатиб с соавторами в своих работах [10] для ряда пунктов Малайзии, кроме продолжительности солнечного сияния и географических координат, в качестве входных данных модели использовал порядковый номер дня в году.

В исследовании [11] входными параметрами для многослойного персептрона послужили значения скорости и направления ветра, относительной влажности воздуха, количество облачности, температура воздуха и парциальное давление.

Тымвиос с соавторами в своей работе [12] для ряда пунктов Кипра провели сравнительный анализ эмпирических моделей, основанных на формуле Ангстрема, и моделей, в основу которых положены искусственные нейронные сети. В качестве входных параметров использовались среднесуточные и среднемесячные значения возможной и реальной продолжительности солнечного сияния, среднесуточные величины максимальной температуры воздуха, энергетическая освещенность солнечной радиации горизонтальной поверхности на верхней границе атмосферы. Исследование показало, что искусственные нейронные сети дают лучшие результаты, чем модель Ангстрема. Среднеквадратическая погрешность моделей на основе нейронных сетей составила 10,5 %, у моделей с использованием формулы Ангстрема – 13,6 %.

Как видно, многочисленные исследователи разработали множество эмпирических моделей, основанных на использовании ИНС, которые определяют связь между солнечной радиацией и различными метеорологическими параметрами. Эти модели могут быть в основном разделены на четыре следующие категории на основе используемых метеорологических параметров:

- 1) модели на основе продолжительности солнечного сияния;
- 2) модели на основе облачности;
- 3) модели на основе температуры воздуха;
- 4) модели на основе других метеорологических параметров. Среди таких метеорологических параметров характеристики ветра, атмосферное давление, количество атмосферных осадков, относительная влажность воздуха;
- 5) смешанные модели, использующие в качестве входных данных различные метеорологические параметры.

Продолжительность солнечного сияния, облачность и температура воздуха являются наиболее широко и часто используемыми параметрами для вычисления суммарной солнечной радиации и его компонентов.

Материалы и методы

Для вычислений потоков солнечной радиации с помощью ИНС использовались наблюдения метеорологической обсерватории Казань-Университет по следующим параметрам: температура воздуха (°C), температура почвы (°C), относительная влажность (%), облачность (балл), состояния диска Солнца и суммарная солнечная радиация за 12-часовой срок.

Для того чтобы определить, как связана суммарная солнечная радиация (Q) и выбранные в данной работе метеорологические параметры: состояние диска Солнца (Sun), общее количество облачности (Cl), температура

почвы (Tn), температура воздуха (T) и относительная влажность воздуха (F) – обратимся к коэффициенту корреляции (r) (табл. 1).

Таблица 1

Связь суммарной солнечной радиации с различными метеорологическими параметрами

Показатели	Sun	Cl	Tn	T	F
Q	0,78	-0,45	0,66	0,61	-0,74

Исходя из табл. 1 видно, что для суммарной солнечной радиации и таких метеорологических параметров, как состояние диска Солнца, температура почвы и температура воздуха, характерна прямая корреляционная зависимость, тогда как для количества облачности и относительной влажности воздуха – обратная.

Различные источники [5–12] для оценки качества прогностических моделей предлагают использовать следующие критерии: $MAPE$ – средняя абсолютная ошибка (%), $RMSE$ (*Root Mean square Error*) – среднеквадратическая ошибка и R^2 – коэффициент детерминации:

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{O_i - S_i}{O_i}, \quad (1)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (S_i - O_i)^2}, \quad (2)$$

$$R^2 = \left(\frac{\sum_{i=1}^N (O_i - \bar{O})(S_i - \bar{S})}{\sqrt{\sum_{i=1}^N (O_i - \bar{O})^2} \sqrt{\sum_{i=1}^N (S_i - \bar{S})^2}} \right)^2, \quad (3)$$

где O_i и \bar{O} – фактическое и среднее фактическое значение за анализируемый период; S_i и \bar{S} – прогностическое и среднее прогностическое значения за анализируемый период; N – количество измерений.

Результаты и обсуждение

В последнее время большое количество исследований, касающихся моделирования и предсказания солнечной радиации, были выполнены с использованием ИНС.

В настоящем исследовании предлагаются десять ИНС-моделей, в качестве входных параметров использующих:

модель 1 – $Q = \tilde{a}(Sun, Cl)$ – состояние диска солнца и количество общей облачности;

модель 2 – $Q = \tilde{a}(Sun, Tn)$ – состояние диска солнца и температуру почвы;

модель 3 – $Q = \tilde{a}(Sun, T)$ – состояние диска солнца и температуру воздуха;

модель 4 – $Q = \tilde{a}(Sun, f)$ – состояние диска солнца и относительную влажность;

модель 5 – $Q = \tilde{a}(Cl, Tn)$ – количество облачности и температуру почвы;

модель 6 – $Q = \tilde{a}(Cl, T)$ – количество облачности и температуру воздуха;

модель 7 – $Q = \tilde{a}(Cl, f)$ – количество облачности и относительную влажность;

модель 8 – $Q = \tilde{a}(T, Tn)$ – температуру воздуха и температуру почвы;

модель 9 – $Q = \tilde{a}(Tn, f)$ – температуру почвы и относительную влажность;

модель 10 – $Q = \tilde{a}(T, f)$ – температуру воздуха и относительную влажность.

Таблица 2

Наилучшие сети с двумя входными параметрами

Тип	ИНС	Производительность обучения	Ошибка обучения	R^2	$RMSE$
Модель 1	2-4-1	0,764	0,2354	0,643	0,179
	2-10-1	0,767	0,0233	0,642	0,179
Модель 2	2-5-1	0,884	0,0123	0,907	0,126
	2-6-1	0,884	0,0124	0,836	0,121
Модель 3	2-3-1	0,876	0,0132	0,821	0,127
	2-6-1	0,876	0,0131	0,821	0,127
Модель 4	2-4-1	0,813	0,0192	0,751	0,149
	2-8-1	0,814	0,0191	0,752	0,149
Модель 5	2-4-1	0,708	0,0283	0,538	0,231
	2-8-1	0,711	0,0280	0,532	0,247
Модель 6	2-4-1	0,693	0,0295	0,517	0,260
	2-7-1	0,693	0,0294	0,517	0,257
Модель 7	2-7-1	0,633	0,0339	0,548	0,251
	2-8-1	0,632	0,0340	0,547	0,231
Модель 8	2-2-1	0,674	0,0331	0,455	0,284
	2-3-1	0,676	0,0307	0,459	0,265
Модель 9	2-2-1	0,692	0,0295	0,608	0,214
	2-5-1	0,691	0,0296	0,607	0,232
Модель 10	2-2-1	0,674	0,0309	0,596	0,246
	2-5-1	0,678	0,0306	0,596	0,245

Модели для обучения настраивались следующим образом: устанавливались минимальные значения скрытых нейронов – в нашем случае 2 и

максимальные – 10. Выбирались функции активации для скрытых и выходных нейронов: тождественная, логическая, гиперболическая и экспонента.

Далее осуществлялся процесс обучения, в результате которого из 50 сетей выбирались 10 наилучших.

Все рассматриваемые модели содержат в себе два входных параметра, число скрытых слоев от двух до десяти и одно прогностическое значение на выходе (табл. 2).

Лучший результат показали модели с таким параметром на входе, как состояние диска Солнца. Так, для модели № 2 средняя производительность составила 0,88, средняя ошибка обучения – 0,0125. А коэффициент детерминации изменяется от 0,82 до 0,91 в зависимости от числа скрытых нейронов.

Несколько меньшую производительность показали модели № 3 и № 4 – 0,878 и 0,813 соответственно. При этом коэффициент детерминации этих моделей меньше, чем у модели № 2, и равен 0,82 и 0,75 соответственно.

Нужно отметить, что у моделей № 1–4 есть существенный недостаток. Одним из входных параметров этих моделей является состояние диска Солнца, наблюдения за которым проводятся лишь в редких случаях. Это делает использование таких моделей затруднительным.

В качестве входных параметров в моделях № 5–10 используются достаточно распространенные метеорологические величины.

Следует отметить, что все шесть моделей показали практически одинаковую производительность обучения 0,67–0,71, но при этом коэффициент детерминации у них сильно варьируется от 0,54 для модели № 5 и до 0,46 для модели № 8.

Для подтверждения качества моделей рассмотрим графики проекции сетей с исходным рядом. На рисунках представлены распределение исходного ряда и значения, рассчитанные с помощью искусственных нейронных сетей, по модели № 2 (рис. 1), в качестве входных параметров здесь использовались состояние диска солнца и температура подстилающей поверхности, и по модели № 5 (рис. 2) – входными данными послужили температура подстилающей поверхности и количество общей облачности. Из рисунков видно, что сеть повторяет ход исходных значений. При этом расчеты, проводимые по модели № 2, наиболее близки к реальным.

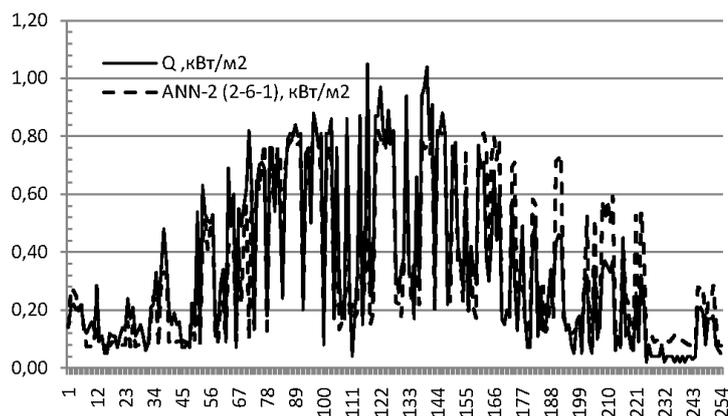


Рис. 1. График построения исходного ряда (Q) и проектируемой сети (ANN-2)

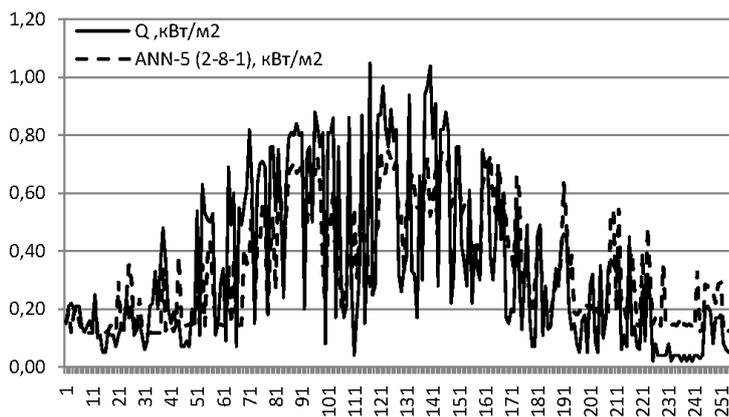


Рис. 2. График построения исходного ряда (Q) и проектируемой сети (ANN-5)

Заключение

Приведенные результаты свидетельствуют, что применение нейросетевых технологий для решения прикладных климатических задач, связанных с обработкой информации и построением моделей, является перспективным направлением исследований.

Анализ полученных результатов позволяет сказать, что аппарат ИНС может давать довольно хорошие результаты при прогнозировании потоков солнечной радиации. Для улучшения качества прогноза впоследствии есть ряд направлений, которые следует рассмотреть в будущем:

- 1) необходимо грамотно и правильно подбирать и задавать параметры на вход ИНС;
- 2) рассматривать сети с большим количеством входных данных, в качестве которых привлекать не только метеорологические параметры;
- 3) разработать процедуру формирования обучающего и контрольного множества.

Библиографический список

1. **Хабутдинов, Ю. Г.** Учение об атмосфере : учеб. пособие / Ю. Г. Хабутдинов, К. М. Шанталинский, А. А. Николаев. – Казань : Казанский гос. ун-т, 2010. – 245 с.
2. **Переведенцев, Ю. П.** Климатические ресурсы солнечной радиации и ветра на территории Среднего Поволжья и возможности их использования в энергетике / Ю. П. Переведенцев, А. А. Николаев. – Казань : Отечество, 2002. – 122 с.
3. **Николаев, А. А.** Косвенные методы расчета характеристик солнечной радиации / А. А. Николаев // Вестник Удмуртского университета. Сер. 6, Биология. Науки о Земле. – 2013. – Вып. 1. – С. 130–135.
4. Нейронные сети. STATISTICA Neural Networks: Методология и технологии современного анализа данных / под ред. В. П. Боровикова. – 2-е изд., перераб. и доп. – М. : Горячая линия – Телеком, 2008. – 392 с.
5. **Sharifi, S. S.** Estimation of daily global solar radiation using wavelet regression, ANN, GEP and empirical models: A comparative study of selected temperature-based approaches / S. S. Sharifi, V. Rezaverdinejad, V. Nourani // Journal of Atmospheric and Solar-Terrestrial Physics. – 2016. – Т. 149 – P. 131–145.

6. **Besharat, Fariba.** Empirical models for estimating global solar radiation: A review and case study / Fariba Besharat, Ali A. Dehghan, Ahmad R. Faghieh // *Renewable and Sustainable Energy Reviews.* – 2013. – Vol. 21. – P. 798–821.
7. **Rehman, S.** Artificial neural network estimation of global solar radiation using air temperature and relative humidity / S. Rehman, M. Mohandes // *Energy Policy.* – 2008. – Vol. 63. – P. 571–576.
8. **Linares-Rodríguez, A.** Generation of synthetic daily global solar radiation data based on ERA-Interim reanalysis and artificial neural networks / A. Linares-Rodríguez, J. Ruiz-Arias, D. Pozo-Vázquez, J. Tovar-Pescador // *Energy.* – 2011. – Vol. 36. – P. 5356–5365.
9. **Koca, A.** Estimation of solar radiation using artificial neural networks with different input parameters for Mediterranean region of Anatolia in Turkey / A. Koca, H. F. Oztop, Y. Varol, G. O. Koca // *Expert Syst Appl.* – 2011. – Vol. 38. – P. 8756–8762.
10. **Khatib, T.** Solar energy prediction for Malaysia using artificial neural networks / T. Khatib, A. Mohamed, K. Sopian, M. Mahmoud // *Int J Photoenergy.* – 2012. – P. 1–16. – URL: www.hindawi.com
11. **Elminir, H. K.** Estimation of solar radiation components incident on Helwan site using neural networks / H. K. Elminir, F. F. Areed, T. S. Elsayed // *Sol Energy.* – 2005. – Vol. 79. – P. 270–279.
12. **Tymvios, F. S.** Comparative study of Ångströms and artificial neural networks methodologies in estimating global solar radiation / F. S. Tymvios, C. P. Jacovides, S. C. Michaelides, C. Scouteli // *Sol Energy.* – 2005. – Vol. 78. – P. 752–762.

References

1. Khabutdinov Yu. G., Shantalinskiy K. M., Nikolaev A. A. *Uchenie ob atmosfere: ucheb. posobie* [The teaching about the atmosphere: teaching aid]. Kazan: Kazanskiy gos. un-t, 2010, 245 p.
2. Perevedentsev Yu. P., Nikolaev A. A. *Klimaticheskie resursy solnechnoy radiatsii i vetra na territorii Srednego Povolzh'ya i vozmozhnosti ikh ispol'zovaniya v energetike* [Climatic resources of solar radiation and wind in the territory of Middle Volga region and their application opportunities in power engineering]. Kazan: Otechestvo, 2002, 122 p.
3. Nikolaev A. A. *Vestnik Udmurtskogo universiteta. Ser. 6, Biologiya. Nauki o Zemle* [Bulletin of Udmurtia University. Series 6. Biology. Geosciences]. 2013, iss. 1, pp. 130–135.
4. *Neyronnye seti. STATISTICA Neural Networks: Metodologiya i tekhnologii sovremenogo analiza dannykh* [Neural networks. STATISTICA Neural Networks. Methodology and technologies of contemporary data analysis]. Ed. by V. P. Borovikov. 2nd ed., revised and supplemented. Moscow: Goryachaya liniya – Telekom, 2008, 392 p.
5. Sharifi S. S., Rezaverdinejad V., Nourani V. *Journal of Atmospheric and Solar-Terrestrial Physics.* 2016, vol. 149, pp. 131–145.
6. Besharat Fariba, Dehghan Ali A., Faghieh Ahmad R. *Renewable and Sustainable Energy Reviews.* 2013, vol. 21, pp. 798–821.
7. Rehman S., Mohandes M. *Energy Policy.* 2008, vol. 63, pp. 571–576.
8. Linares-Rodríguez A., Ruiz-Arias J., Pozo-Vázquez D., Tovar-Pescador J. *Energy.* 2011, vol. 36, pp. 5356–5365.
9. Koca A., Oztop H. F., Varol Y., Koca G. O. *Expert Syst Appl.* 2011, vol. 38, pp. 8756–8762.
10. Khatib T., Mohamed A., Sopian K., Mahmoud M. *Int J Photoenergy.* 2012, pp. 1–16. Available at: www.hindawi.com
11. Elminir H. K., Areed F. F., Elsayed T. S. *Sol Energy.* 2005, vol. 79, pp. 270–279.
12. Tymvios F. S., Jacovides C. P., Michaelides S. C., Scouteli C. *Sol Energy.* 2005, vol. 78, pp. 752–762.

Николаев Александр Анатольевич

кандидат географических наук, доцент,
кафедра метеорологии, климатологии
и экологии атмосферы, Казанский
(Приволжский) федеральный
университет (Россия, г. Казань,
ул. Кремлевская, 18)

E-mail: Aleksandr.Nikolaev@kpfu.ru

Nikolaev Aleksandr Anatolevich

Candidate of geographical sciences,
associate professor, sub-department
of meteorology, climatology and
atmosphere ecology, Kazan (Volga region)
Federal University (18 Kremlyovskaya
street, Kazan, Russia)

Исмагилов Наиль Вагизович

кандидат географических наук, доцент,
кафедра метеорологии, климатологии
и экологии атмосферы, Казанский
(Приволжский) федеральный
университет (Россия, г. Казань,
ул. Кремлевская, 18)

E-mail: Nail.Ismagilov@kpfu.ru

Ismagilov Nail Vagizovich

Candidate of geographical sciences,
associate professor, sub-department
of meteorology, climatology and
atmosphere ecology, Kazan (Volga region)
Federal University (18 Kremlyovskaya
street, Kazan, Russia)

УДК 551.5

Николаев, А. А.

Применение нейросетевых технологий для вычисления потоков суммарной солнечной радиации / А. А. Николаев, Н. В. Исмагилов // Известия высших учебных заведений. Поволжский регион. Естественные науки. – 2017. – № 3 (19). – С. 68–77. DOI: 10.21685/2307-9150-2017-3-7