

Research on the Prediction of the Impact of Surface Thermal Environment Effects on the Total Agricultural Grain Output in the Beijing-Tianjin-Hebei Region

Yantong Guo Binghui Li Sihao Chen

Tianjin University of Finance and Economics, Tianjin, 041600, China

Abstract

China has a complex terrain and diverse climate, and is significantly influenced by the monsoon, resulting in drastic weather changes in various regions and bringing considerable uncertainty to agricultural production. Accurately assessing the impact of climate on thermal effects and agricultural output value has long been a key concern for the government, the public and the scientific research field. Based on the data from the China Meteorological Data Network and the “Monthly Report of Ground Meteorological Records”, this paper uses the SPSS gray-scale correlation analysis method to screen out the five indicators with the strongest correlation with the surface thermal environment effect from factors such as the maximum temperature, minimum temperature, average temperature, wind speed, precipitation, sunshine, and humidity. And a BP neural network model was constructed to analyze and predict the surface thermal environment effect in the Beijing-Tianjin-Hebei region. Subsequently, based on the agricultural panel data of 13 cities in the Beijing-Tianjin-Hebei region from 2011 to 2020, the fixed effect model was used to empirically test its impact on agricultural production capacity. The results show that the surface thermal environment effect has a negative impact on agricultural production capacity at a significance level of 5%, and its lag of one period also has a significant influence. Based on this, the article suggests that the Beijing-Tianjin-Hebei region should adjust its planting structure in accordance with local conditions, improve the agricultural insurance and technological innovation system, and enhance agricultural meteorological services to address the challenges brought about by changes in the thermal environment.

Keywords

Surface thermal environment effect Grey correlation BP neural network regression prediction Fixed panel model Agricultural production

京津冀地表热环境效应对农业粮食总产量的影响预测的研究

郭彦彤 李冰蕙 陈思含

天津财经大学, 中国 · 天津 041600

摘 要

中国地形复杂、气候多样, 受季风影响显著, 导致各地天气变化剧烈, 给农业生产带来较大不确定性。准确评估气候对热效应及农业产值的影响, 是政府、公众和科研领域长期关注的重点。本文基于中国气象数据网与《地面气象记录月报表》资料, 利用SPSS灰度关联分析法, 从最高气温、最低气温、平均气温、风速、降水、日照、湿度等因素中筛选与地表热环境效应相关性最强的五项指标, 并构建BP神经网络模型对京津冀地表热环境效应进行分析与预测。随后, 基于2011—2020年京津冀13市农业面板数据, 采用固定效应模型实证检验其对农业生产能力的影响。结果显示, 地表热环境效应对农业生产能力存在5%显著性水平的负向作用, 且其滞后一期同样具有显著影响。据此, 文章建议京津冀应因地制宜调整种植结构, 完善农业保险和技术创新体系, 加强农业气象服务, 以应对热环境变化带来的挑战。

关键词

地表热环境效应; 灰色相关性; BP神经网络回归预测; 固定面板模型; 农业生产

1 引言

1.1 研究背景

全球气候变暖导致极端天气频发, 给农业生产带来巨大不确定性。美国商务部数据显示, 天气因素影响约 1/3 的

美国经济活动, 全球范围更超 4/5 [1]。作为《联合国气候变化框架公约》主要缔约方, 中国在习近平主席多次气候峰会上强调了应对气候变化的重要性, 彰显了稳定粮食安全与推动可持续发展的国家决心 [2]。

1.2 研究意义

中国地形复杂、季风气候显著, 各地天气波动大, 对农业生产影响深远。IPCC《全球变暖 1.5℃特别报告》提出实现净零排放以避免灾难性气候 [3], 但考虑到区域差异,

【作者简介】郭彦彤 (2004—), 女, 中国山西临汾人, 本科, 从事数学与应用数学研究。

亟须开展区域性研究。本研究聚焦气候相似且农业紧密相关的京津冀地区,深入分析地表热环境效应对粮食总产量的影响,以期为该区域农业在气候变化背景下的决策与规划提供科学依据[4]。

1.3 研究现状

气候变化对农业生产及粮食安全的影响已成为全球及我国政府和学术界关注的重点,地表热环境效应对粮食总产量的作用尤其凸显。现有研究多聚焦于气候因子与作物生长的单一维度关联,但针对京津冀区域的综合性分析尚属少见。本课题通过整合气象与农业统计数据,从地域特征和作物类型差异出发,采用定量模型深入挖掘气候变化对区域粮

食产量的影响机制,旨在丰富我国气候—农业研究方法,为稳定粮食生产和制定适应性政策提供科学依据。

1.4 研究思路

本研究首先从中国气象数据网及各省市《地面气象记录月报表》提取日值资料,筛选与地表热效应高度相关的最高温、最低温、平均温、累积降水、累积日照五项指标并完成预处理;然后以BP神经网络回归模型量化并预测气候因子对地表热环境效应的影响;接着结合人均农业机械动力、综合生产能力、劳动生产率、农药化肥用量和绿化率等数据,预测京津冀地区粮食总产量并评估气候风险;最后检验模型稳定性与预测精度,探讨局限并提出改进建议。




图1 气候因素对农业产出的影响机制分析框架

通过这一系列的研究步骤,我们旨在深入理解京津冀地区地表热环境对农业粮食总产量的影响规律,为应对气候变化下的农业生产提供科学支持和决策参考

1.5 研究内容

1.5.1 京津冀地表热环境效应的影响因素研究及预测

我们根据年月的不同情况分别采用不同的数据整理方式。在每月数据中,我们定义公式 地表热环境效应(℃)=绝对值的(平均最高气温/地温的平均值(℃)—平均最低气温/地温的平均值(℃))。在各年数据中,我们发现神经回归网络模型和数据相关性很强。神经回归网络是一种基于神经网络结构的回归模型,用于建立输入与输出之间的非线性映射关系。其具体模型可以包括多个神经元组成的隐藏层,以及一个输出层,其中隐藏层和输出层之间通过权重连接。在神经回归网络中,隐藏层的神经元通过激活函数将输入信号进行非线性变换,

最终输出层的神经元将隐藏层的输出加权求和后经过激活函数得到最终的输出结果。通过神经网络回归的预测模型,我们对这些指标进行了深入分析,并成功建立了预测模型。我们定义经过拟合度分析,模型对数据的拟合程度较高,具有较强的预测能力。这一分析过程不仅加深了我们对京津冀地区气候变化的理解,还为进一步探究地表热环境对农

业粮食总产量的影响奠定了坚实的基础。同时,该模型的建立也为未来的气候预测和农业生产规划提供了可靠的工具和方法。

1.5.2 京津冀影响农业总产值各个指标分析

农业关系国计民生,粮食安全始终是国家发展的核心问题。为深入了解京津冀地区农业发展状况,我们基于各市政府统计年鉴数据,选取了人均农业机械总动力、粮食综合生产能力、农业劳动生产率、农药化肥施用量、农村绿化率等关键指标,全面分析了2011年至2020年间十三个市的农业发展变化。通过固定面板数据模型,我们实证检验了地表热环境效应对农业生产的影响,揭示了气候因素与农业产值之间的密切关联。为确保研究的科学性,我们对原始数据进行了清洗与异常值处理,提升了分析的可靠性。后续将结合气候数据构建更精确的预测模型,探索气候变化背景下农业面临的挑战及应对策略。研究成果将为京津冀地区乃至全国的农业可持续发展和政策制定提供科学支撑。

2 数据与方法

2.1 数据来源

中国气象数据网、中国地面气候资料日值数据集来源于各省、市、自治区气候资料处理部门逐月上报的《地面

气象记录月报表》的信息化资料。

为了全面研究地表热环境效应对京津冀地区农业生产的影响,我们进行了广泛的数据搜集和分析。首先,我们从国家气象局的官网以及各市政府官网中获取了与气候相关的数据指标,如平均湿度、累积日照、累积降水、平均风速、平均温度等。这些数据对于研究地表热环境效应具有重要意义,因为它们反映了地区气候的特点和变化趋势[7]。

2.2 指标选择和说明

我们整理了2011年至2020年京津冀地区的气候与农业相关数据,涵盖各项指标的样本数、均值、标准差、最大值、最小值及分位数等统计特征,为后续建模打下了基础。在气候指标分析中,我们采用逐月方法研究地表热环境效应的季节变化,并将其定义为平均最高气温与地温平均值之比减去平均最低气温与地温平均值之比的绝对值,从而更精准反映气候变化趋势。与此同时,我们从各市统计年鉴中提取了农业机械总动力、粮食综合生产能力、农业劳动生产率、农药化肥施用量、农村绿化率等关键指标,用以评估农业发展水平。这些数据的整合分析不仅为神经网络模型的构建提供了充分支撑,也为深入揭示地表热环境与农业产出之间的关系、提升农业应对气候变化的科学决策能力提供了依据。

2.3 研究方法

2.3.1 灰色关联性分析

灰色关联性模型是一种用于分析变量之间关联程度的方法,特别适用于具有少量数据和不完整信息的情况。该模型基于灰色系统理论,通过计算变量之间的关联度,可以揭示它们之间的联系和影响程度。

灰色关联性模型在数据分析、决策支持、系统优化等领域有着广泛的应用,特别适用于数据不完整、信息不充分的情况下对变量之间关联性进行分析和研究。

2.3.2 BP神经网络回归预测

BP神经网络(Backpropagation Neural Network)是一种常见的人工神经网络模型,用于解决回归和分类等问题。在回归问题中,BP神经网络可以用于建模输入变量与连续输出变量之间的关系。

BP神经网络通常由输入层、隐藏层和输出层组成。输入层接收输入数据,隐藏层进行特征提取和非线性变换,输出层产生最终的预测结果。

通过反复迭代训练,BP神经网络可以逐渐学习到输入变量与输出变量之间的复杂非线性关系,从而实现对回归问题的预测。

2.3.3 固定面板模型

固定面板模型(Panel Data Model)也称为纵向数据模型或混合数据模型,是一种同时考虑横向和纵向维度的统计分析方法。面板数据由多个个体(如个人、家庭、公司等)在不同时间点上的观测数据组成,通常包含了横截面数据和时间序列数据,因此可以更好地捕捉个体间和时间间的变

异性。

固定面板模型可以分为固定效应模型(Fixed Effects Model)和随机效应模型(Random Effects Model)两种。固定效应模型假设每个个体都有特定的效应,随机效应模型则假设个体效应是随机抽样的。研究人员可以根据具体问题和数据特点选择合适的固定面板模型进行分析。

3 基于BP神经网络回归模型对地表热环境效应的影响因素研究及预测

3.1 指标选择与灰色关联分析

3.1.1 灰色关联分析概念

灰色关联度分析是度量两种事物或数据关联程度,如果两种事物在大小、方向、速度等方面随时间变化表现出越高的相似性,则表明其关联度越大,反之则越小。换言之依据两组数据绘出的曲线展现出的相似性越大,其关联度越大。数据的关联程度以0至1之间的数值表示。此方法其实就是用来计算指标系统之间的灰色关联度来描述指标间强或者弱的顺序关系的。两个系统之间会随着时间或者其他的要素的改变而发生相应的变化,藉此就可以得到二系统之间的关联度大小[9]。

第一步确定分析数列。

设参考数列又称母序列为 $Y_i = \{Y_i(t)\}$;设比较数列又称子序列为 $X_j = \{X_j(t)\}$ 第二步无量纲化在本文中选择初值化初值化处理

第三步计算关联系数。 Y_i 和 X_j 的关联系数为:

$$\varepsilon_i(t) = \frac{\min \min |y(t) - x(t)| + \rho \max \max |y(t) - x(t)|}{|y(t) - x(t)| + \rho \max \max |y(t) - x(t)|} \quad \text{公式(1)}$$

其中 $\rho \in (0, \infty)$,称为分辨系数。通常 ρ 的取值区域为 $(0, 1)$,本文取 $\rho = 0.5$ 。

3.1.2 灰色关联分析步骤

我们采用SPSS灰色关联性分析最高气温,最低气温,平均气温,平均风速,累积降水,累积日照,平均湿度,高程,纬度,经度。

由于关联系数是比较数列和参考数列在各个时刻关联程度的值,数据过于庞大和分散不利于整体性对比,所以要将各个时刻数据整合成一个值,就是其平均值,关联度

$$R_i = \frac{1}{n} \sum_{t=1}^n \varepsilon_i(t) \quad \text{公式(2)}$$

在进行灰色关联度分析时,我们首先对于10个评价项(最高气温、最低气温、平均气温、平均风速、累积降水、累积日照、平均湿度、高程、纬度、经度)以及1560项数据进行初值化和均值化处理。初值化是指将这一序列的数据统一除以最开始的值,以整理数据到接近1的量级附近。而均值化则是将序列的数据除以其均值,以将数据归一化到1的量级附近。

接着,以地表热环境效应作为“参考值”(母序列),我们进行灰色关联度分析,研究10个评价项与地表热环境

效应之间的关联关系（关联度）。在计算过程中，我们采用了分辨系数为 0.5 的灰色关联度分析方法，并结合关联系数计算公式，计算出关联系数值。通过这些数值，我们进一步计算出关联度值，以评价和判断不同评价项与地表热环境效应之间的关联程度。

这一研究方法旨在从多个维度分析地表热环境效应与各项评价指标之间的关系，为进一步理解地表热环境对农业生产的影响提供科学依据和参考。同时，通过严谨的数据处理和分析方法，我们确保了研究结果的准确性和可靠性。

通过这种方法，我们可以从数据中选取与“参考值”相关性最强的前五个指标进行分析。这种方法可以帮助我们更好地理解各评价项与地表热环境效应之间的关系，从而为农业生产提供更科学的支持和决策参考。

3.2 数据描述性统计及归一化

3.2.1 总体描述结果

为了观察统计指标数据序列平稳性等特性，利用 python 对所选取的变量指标数据进行统计特征分析，变量的描述性统计如表所示。

表 1 灰色关联系数（部分）

索引项	最高气温	最低气温	平均气温	平均风速	累积降水	累积日照	平均湿度	高程	经度	纬度
2011/1/1	0.998999	0.742908	0.999608	0.997669	0.999173	0.997746	0.998589	0.998496	0.997971	0.997922
2011/2/1	0.997236	0.781972	0.998233	0.996639	0.997857	0.996881	0.996667	0.997018	0.996494	0.996446
2011/3/1	0.999739	0.848076	0.999574	0.999243	0.999699	0.99906	0.999685	0.999907	0.999567	0.999518
2011/4/1	0.998628	0.976832	0.998925	0.998638	0.999746	0.998621	0.999455	0.99948	0.998954	0.998905
2011/5/1	0.998393	0.905585	0.998005	0.998485	0.998604	0.998243	0.999167	0.999285	0.998759	0.99871
2011/6/1	0.9981	0.795865	0.997278	0.998776	0.997787	0.998432	0.998703	0.9992	0.998674	0.998626
2011/7/1	0.998072	0.759932	0.997108	0.998955	0.997518	0.998824	0.998317	0.999172	0.998646	0.998598
2011/8/1	0.998109	0.755667	0.997196	0.998985	0.996121	0.998685	0.998239	0.999168	0.998642	0.998594
2011/9/1	0.998446	0.884757	0.998112	0.999059	0.997004	0.998669	0.998592	0.999274	0.998748	0.9987
2011/10/1	0.998849	0.964559	0.998989	0.99933	0.998703	0.999102	0.998769	0.999457	0.998931	0.998883
2011/11/1	0.999961	0.871386	0.999484	0.999888	0.998999	0.999983	0.99946	0.999944	0.99953	0.999482
2011/12/1	0.998584	0.786098	0.99962	0.997741	0.99909	0.997811	0.997765	0.998151	0.997626	0.997577
2012/1/1	0.999191	0.742912	0.999705	0.998073	0.999452	0.998155	0.998239	0.998503	0.997978	0.997929
2012/2/1	0.998325	0.733486	0.999389	0.997265	0.998618	0.997325	0.997999	0.997926	0.997402	0.997354
2012/3/1	0.999636	0.8189	0.998656	0.999943	0.998248	0.99985	0.999389	0.999195	0.999721	0.99977
2012/4/1	0.998679	0.959373	0.998696	0.998576	0.99991	0.998664	0.999349	0.999426	0.9989	0.998851
2012/5/1	0.998282	0.878989	0.997753	0.998724	0.99931	0.998274	0.999061	0.99926	0.998735	0.998686
2012/6/1	0.998106	0.832777	0.997465	0.998837	0.996906	0.998939	0.99858	0.999234	0.998708	0.99866
2012/7/1	0.998063	0.746243	0.997085	0.998865	0.992828	0.998798	0.998336	0.999163	0.998637	0.998588
2012/8/1	0.998122	0.805388	0.997307	0.999016	0.99758	0.998507	0.998363	0.999205	0.998679	0.998631
2012/9/1	0.998475	0.917937	0.998067	0.999033	0.998754	0.998579	0.998556	0.999286	0.99876	0.998711
2012/10/1	0.998873	0.949263	0.999012	0.999187	0.999869	0.998741	0.99893	0.99947	0.998944	0.998895
2012/11/1	0.997518	0.863467	0.996674	0.997987	0.997082	0.997848	0.998008	0.997472	0.997996	0.998045
2012/12/1	0.99931	0.732819	0.99962	0.998026	0.999432	0.998496	0.998101	0.998541	0.998016	0.997967

表 2 灰色关联性和排名

评价项	关联度	排名
平均风速	0.997	1
平均湿度	0.997	2
累积日照	0.997	3
平均气温	0.997	4
累积降水	0.997	5
最高气温	0.875	6
最低气温	0.845	7
经度	0.675	8
纬度	0.657	9
高程	0.563	10

表3 总体描述表格

返回数组	平均湿度	累积日照	累计降水	平均风速	平均气温	地表热环境效应
个数	1560	1560	1560	1560	1560	1560
平均值	58.421	202.513	44.0894	2.19716	12.413	19.0246
标准差	12.3061	47.0284	56.6674	0.450474	10.9463	308.585
最小值	27.7849	44.1226	1.87278e-05	1.31636	-12.4666	0.48444
25%	48.4968	173.707	4.46217	1.83939	2.43163	1.03878
50%	57.8948	203.204	19.5003	2.13635	14.0532	2.08879
75%	68.7313	235.346	65.2604	2.4932	22.3685	5.27447
最大值	85.755	329.318	342.348	3.67436	28.5886	11845.3

3.2.2 数据归一化处理

在实际生活中,不同的变量导致数值之间产生不同,就会引起神经网络预测的结果出现“过拟合”情况,根据相关文献[4],为了提高模型的收敛速度和稳定性,提高模型的泛化能力:归一化可以将数据缩放到相似的范围,避免了不同特征之间的差异过大,有利于模型更快地收敛并且更加稳定。减少特征之间的相关性,有利于模型更好地泛化到新的数据上。

将对2011年至2010年京津冀十三市逐月平均湿度、累积日照、累积降水、平均风速和平均温度数据进行归一化处理,将输入BP神经网络的数据转为0~1的,归一化对数据进行归一化处理,处理后的数据样本取值区间为0~1。




图2 处理后的样本取值区间

3.3 BP神经网络模型的原理

BP神经网络模拟人类思维,是在误差反向传播算法基础上训练的多层前馈神经网络。BP神经网络通常由一个前馈层、一个隐含层和一个输出层组成。如图所示,输入和输出层是单层结构,神经元的数量由训练模式决定。隐含层可以设置为一个或多个层,神经元的数量,也称为隐含层的节点数,如图




图3 神经网络模型原理

x 为 m 维向量 y 为 n 维向量, 隐含层有 q 个神经元 假设 N 个样本数据, $\{y_t, x_t, t=1, 2, N\}$

从输入层到隐含层的权重记为 $V_{jk}(j=1, 2, m, k=1, 2, q)$

从隐含层到输出层的权重记为 $W_{ki}(k=1, 2, q, i=1, 2, n)$

记第 t 个样本 $x_t = \{x_1(t), x_2(t), \dots, x_m(t)\}$ 输入网络时, 隐含层单元的输出为 $H_k(t)(k=1, 2, q)$, 输出层单元的输出为 $f(t) = \{f_1(t), f_2(t), \dots, f_n(t)\}$, 即

$$H_k(t) = G \left(\sum_{j=1}^m v_{jk} x_j(t) \right), k=1, 2, q$$

$$f_i(t) = f \left(\sum_{k=1}^q \omega_{ki} H_k(t) \right), i=1, 2, n$$

V_{0k} 为对应输入神经元的阈值, 而 $x_0(t)$ 通常为 1;

W_{0i} 为对应隐含层神经元的值, 而 $H_0(t)$ 通常为 1

$g(x), f(x)$ 分别为隐含层、输出层神经元的激发函数。

常用的激发函数有 $f(x) = \tanh(x)$ 双曲正切函数

通过输入的 N 个样本数据, 使得真实的 y 值与网络的预测值的误差最小即可, 它变成了一个优化问题, 记 $= \{V_{ik}; W_{ki}\}$, 则优化问题如下

$$\min E(w)=\frac{1}{2}\sum_{it}(\gamma_i(t)-\gamma_t(t))^2=\frac{1}{2}\sum_{it}\left[y_i=t-f\left(\sum_{k=0}^qw_{ki}H_k(t)\right)\right]^2$$

在各年的研究中，我们采用了神经网络分析模型对地表热环境效应进行预测。在建立神经网络模型时，我们将平均湿度、累积日照、累积降水、平均风速和平均温度作为输入层的自变量 (x)，用来预测地表热环境效应的结果。通过设定多个隐藏层，每个隐藏层包含多个神经元，并根据不同特征之间的重要性和关联程度赋予不同的权重，我们建立了一个复杂而准确的神经网络模型。这个模型通过输入的 N 个样本数据，不断调整参数，使得模型的预测结果与真实的地表热环境效应值之间的误差最小化，从而达到了更准确的预测效果。

3.4 BP 神经网络模型的步骤

在各年的研究中，我们采用了神经网络分析模型对地表热环境效应进行预测。在建立神经网络模型时，我们将平均湿度、累积日照、累积降水、平均风速和平均温度作为

输入层的自变量 (x)，用来预测地表热环境效应的结果。

将备件需求量作为输出，将 5 个因素平均湿度、累积日照、累积降水、平均风速和平均温度 变量进行输入，该 BP 神经网络模型存在 5 个输入节点和 1 个输出节点。数据获取及训练样本构建其中训练样本的特征输入变量用 x 表示，输出变量用 y 表示导入神经网络回归模块 MLPRegressor，利用 MLPRegressor 创建神经网络回归对象 clf，调用 clf 对象中的 fit() 方法进行网络训练调用 clf 对象中的 score 方法，获得神经网络回归的拟合优度判决系数

3.5 基于 BP 神经网络模型预测逐年的地表热环境效应值的预测

接下来将 2011 年至 2010 年京津冀十三市逐年平均湿度、累积日照、累积降水、平均风速和平均温度归一化，预测样本的构建其中预测样本的输入特征变量，调用 clf 对象中的 predict() 可以对测试样本进行预测，获得其预测结果代入此神经网络回归模型预测逐年的地表热环境效应值



图 4 真实值和预测值差距




图 5 地表热环境效应值

4 基于固定面板数据模型分析地表热环境效应对农业产生的影响

4.1 研究方法介绍

固定面板模型介绍：

时点个体固定效应模型就是对于不同的截面（时点）、不同的时间序列（个体）都有不同截距的模型。如果确知对于不同的截面、不同的时间序列（个体）模型的截距都显著不相同，那么应该建立时点个体固定效应模型：

$$y_{it} = \lambda_i + y_t + \sum_{k=1}^K \beta_k x_{kit} + u_{it}$$

4.2 数据来源、变量选取以及描述性统计

首先说明农业数据的原始数据来源，然后依据客观性原则，分别对相关变量进行说明，为了观察统计指标数据的序列平稳性，利用 Stata17.0 MP 软件对所选取的变量指标数据进行统计特征分析。

4.2.1 数据来源

本文选取 2011-2020 年北京、天津、河北共计 13 个市的农业面板数据集进行分析。原始数据中农业劳动生产能力、农业机械总动力和每公顷农用化肥施用折纯量来自《中

国农村统计年鉴中国城乡建设统计年鉴》、粮食综合生产能力和农村绿化率来自各市统计年鉴。地表热环境效应值则根据 BP 神经网络模型预测得出。

4.2.2 变量选取

研究地表热环境效应对农业生产力的具体影响时，将农业劳动生产能力（万元）、每公顷农用化肥施用折纯量、农业机械总动力（万千瓦）作为农村绿化率（%）、地表热环境效应值作为解释变量，将粮食综合生产能力（万吨）作为被解释变量。在产出方面，本章选取的农业产出变量是粮食综合生产能力（万吨）；在投入方面，有三种主要的投入要素，其中劳动投入选取的是农业劳动生产能力（万元），化肥投入采用的是每公顷农用化肥施用折纯量，机械投入采用的是农业机械总动力（万千瓦）。此外还使用了农村绿化率（%）作为变量之一。

4.2.3 描述性统计

为了观察统计指标数据序列平稳性等特性，利用 Stata 17.0 MP 软件对所选取的变量指标数据进行统计特征分析变量的描述性统计如下表所示。

表 4 变量的描述性统计

变量名	样本量	最大值	最小值	平均值	标准差	中位数	峰度	偏度	CV
粮食综合生产能力 万吨	130	28852.982	6934.472	14230.857	3527.43	13823.243	4.263	1.531	0.248
农药、化肥施用量 万吨	130	666.84	171.732	346.863	82.929	334.891	4.123	1.554	0.239
农村绿化率 %	130	20.004	4.968	10.009	2.556	9.632	3.784	1.581	0.239
农业劳动生产 万元	130	9029414	8880614	2951212556	1969440246	2438235	1.192	1.402	0.667
农业机械总动力 万千瓦	130	42297274	3391301	13862043.88	9393594.174	1151701 5	1.006	1.374	0.678
地表热环境效应值	130	175.006	86.254	109.721	12.705	107.373	5.475	1.534	0.116

4.3 多重共线性检验

为保证实证结果的有效性，本文利用 Pearson 相关系数值对数据进行共线性分析。通过分析可知，两两之间的相关系数绝对值均小于 0.80，所以初步判断不存在多重共线性问题。

通过 VIF 检验可知，上述指标中不存在 VIF > 5 与容忍度 Tolerance < 0.20 的项，故不存在多重共线性问题。

4.4 固定面板模型结果分析

以粮食综合生产能力（万吨）作为被解释变量，以农业劳动生产能力（万元）、每公顷农用化肥施用折纯量、农业机械总动力（万千瓦）作为农村绿化率（%）、地表热环境效应值作为解释变量。采用普通最小二乘法模型（Ordinary Least Square, OLS）、固定效应模型（Fixed Effects, FE）、随机效应模型（Random Effects, RE）研究地表热环境效应对农业发展产生的影响，回归结果如下表

所示。

首先进行 F 检验，F 统计量的结果 P 值为 0.0230 < 0.05，即在 5% 的显著性水平上拒绝原假设，因此否定了 OLS 回归模型的结果。后通过豪斯曼检验得出 P 值为 0.001 < 0.01，即在 1% 的显著性水平上拒绝原假设。因此，本文最终选择使用固定效应模型（RE）进行实证结果的回归分析，结果如表 5 列（4）所示。

从被解释变量角度分析，京津冀地区粮食综合生产能力即农业生产能力的滞后一期在 1% 的显著性水平为正，即前一期的农业生产能力对后一期的农业生产能力存在显著的正向影响。

从解释变量角度分析，京津冀地区地表热环境效应对农业生产能力在 5% 的显著性水平上呈现负向作用。因此京津冀地区应通过改变种植时间、品种选择、灌溉方式等措施可以一定程度上缓解地表热环境效应带来的损失。通过

表 5 列（4）可知，地表热环境效应值 每提高一个单位，农业生产能力发展将降低 0.0028 个单位，影响效果虽然显著，但是力度 不是很大。若从滞后一期的地表热环境效应值进 行分析，无论是传统 OLS 回归还是固定效应 与随机效应回归，均表示滞后一期的地表热环境效应值对农业生产能力产生负向作用，但是 相对较弱。

表 5 OLS、RE、FE 回归结果

变量	传统 OLS	随机效应回归（RE	固定效应回归（PE	样本量
农药、化肥施用量	0.0000** (0.80116640)	0.0937** (0.06864790)	0.0092** (0.06529280)	780
农村绿化率 %	0.0391** (0.07185460)	0.0055** (0.06430180)	0.0006** (0.06218650)	780
农业劳动生产万 元	0.0132** (0.19129600)	0.0083** (0.05466090)	0.0007** (0.05305110)	780
农业机械总动力 万千瓦)	0.0141** (0.02662810)	0.0079** (0.05340000)	0.0073** (0.05182510)	780
地表热环境效应值	-0.0629** (0.14151940)	-0.0045** (0.09454990)	-0.0028** (0.07888200)	780
常数项	3.48462	3.672431	4.137556	780
变量数	780	780	780	

5 结论和建议

5.1 气候因素对地表热环境效应的影响

京津冀地区气候变暖和降水格局变化显著增强了地表热环境效应，高温干旱条件下地表温度波动更大，需加强温室气体减排、生态保护与气象监测预警，保障区域可持续发展与粮食安全。

5.2 地表热环境效应对农业的不利影响

高温环境降低了农业劳动效率，干扰化肥与灌溉决策，增加生产不确定性与成本；对敏感作物与区域的差异化影响加剧了区域发展不平衡，亟须统筹应对。

5.3 农业适应地表热环境效应的对策建议

因地制宜调整种植结构，推广耐热作物品种与设施农业，实施错峰种植；

强化耐热新品种选育、节水灌溉和精准施肥技术的研究与推广；

完善农业保险，提高覆盖率与赔付水平，分散极端天气风险；

健全农业气象服务系统，提供精准预警与种植指导，提升农户应对能力。

参考文献

[1] 李竹薇, 田颖楠, 韩奕娆, 刘瀚文. 我国本土气温指数期货产品的研发设计 ——源于京津冀“首都经济圈”核心功能区的气温数据[J].中国证券期货, 2024(06)

[2] 代明慧, 于法稳.气候变化背景下农业绿色发展能力提升[J].研究中州学刊, 2024(04)

[3] 张晗.一种用于时间序列预测的平移不变神经网络结构[J].北京邮电大学学报, 2024 (03)

[4] 李颜平, 吴刚. 基于典型数据集的数据预处理方法对比分析 [J] 沈阳工业 大学学报, 2022, 44(2) : 185-192.

[5] 周寅.气候变化对我国粮食产量影响的测度及应对策略研究[D].华东交通大学, 2023, (04)

[6] 李海东. 生物多样性保护适应气候变化 的管理策略 [J]. 生态学报., 2020,40(11):3844-3850

[7] 樊星. IPCC 第六次评估报告第一工作组报告主要结论解读及建议[J]. 环境 保护, 2021, 49(Z2):44-48.

[8] 张蒙殷培红. 运用 NbS 推进应对气候变化与保护生物多样性协同治理[J].环境生态学, 2022,4(04) :51-58+80.

[9] 李钧官海鹏. 粮食供求形势及农业政策性金融职能定位研究[J]. 农业发 展与金融