Downscaling a conservazione di massa di prodotti ODIAC su emissioni di CO_2 fossile con predittori di Osservazione della Terra: Shanghai Pudong e Città Metropolitana di Milano

Nicola Romanato[1,2][0009-0007-3190-1249], Denis Maragno[1]

[1] Dipartimento di Architettura e Arti, Università Iuav di Venezia, nromanato@iuav.it, dmaragno@iuav.it
[2] Dottorato Nazionale in Osservazione della Terra, Dipartimento di Ingegneria Civile, Edile e Ambientale, Sapienza Università di Roma

Abstract. Gli inventari globali di CO_2 fossile garantiscono confronti omogenei tra città, ma non raggiungono la scala dell'azione climatica locale. Si propone un downscaling a conservazione di massa che porta ODIAC da ≈1 km a ≈250 m con un Random Forest e dieci predittori di Osservazione della Terra globali e open, senza luci notturne, evitando la circolarità con il proxy di costruzione dell'inventario. A configurazione fissa, Shanghai Pudong e Milano raggiungono R^2 in validazione spaziale di 0,65 e 0,67 con predittori dominanti diversi (quota, NO_2): la procedura è trasferibile, i pesi appresi no. Il prodotto conserva i totali dell'inventario e restituisce emissioni pro capite per unità amministrativa, con un divario Pudong–Milano tra 1,98× e 3,06× a parità di densità.

Parole chiave: Downscaling delle emissioni di CO_2, ODIAC, Random Forest, Sentinel-5P TROPOMI, Google Earth Engine.

1 Dagli inventari globali alla scala urbana: circolarità e trasferibilità del downscaling

Gli inventari globali grigliati di CO_2 fossile consentono confronti omogenei tra città, ma la loro risoluzione è più ampia rispetto alle unità urbane all'interno delle quali si pianifica l'azione climatica. ODIAC (Open-source Data Inventory for Anthropogenic CO_2) distribuisce emissioni mensili a 1/120°, allocando le sorgenti diffuse con la radianza delle luci notturne osservate da satellite e le grandi sorgenti puntuali con un database georiferito [1, 2]. Il downscaling con apprendimento automatico, basato su proxy ad alta risoluzione, anomalie di XCO_2 da satellite o Random Forest addestrati su ODIAC [3–5], lascia aperte due questioni: la circolarità delle luci notturne usate come predittore rispetto al proxy di costruzione di ODIAC e la trasferibilità dei pesi appresi tra città di morfologia diversa [6].

Si presenta una pipeline che ridistribuisce ODIAC da 1/120° (≈1 km) a 1/480° (≈250 m) con un Random Forest a conservazione di massa e soli predittori di

Osservazione della Terra (OT) open-source, elaborati in Google Earth Engine (GEE) [7]. La stessa configurazione è applicata a Shanghai Pudong, nodo costiero-industriale dominato da sorgenti puntuali, e alla Città Metropolitana di Milano, area continentale a regime emissivo diffuso, per valutare abilità predittiva, gerarchia dei predittori appresa ed emissioni pro capite a parità di densità.

2 Pipeline per il downscaling a conservazione di massa in Google Earth Engine

2.1 ODIAC 2023 come target: Shanghai Pudong e Città Metropolitana di Milano

Il target è ODIAC 2023 (release 2024), come proxy delle emissioni di CO_2 da combustione fossile [2], con i dodici raster mensili sommati in un raster annuale (tCO_2 cella^{-1} anno^{-1}). La trasformazione affine dell'estensione ritagliata è la griglia di riferimento di tutte le esportazioni da GEE, così che target e predittori siano allineati al pixel. L'AOI di Pudong (1 402,5 km^2, 36 jiedao, 8 670 celle ODIAC, 68,0 $MtCO_2$ anno^{-1}) include il polo termoelettrico e portuale di Waigaoqiao; quella di Milano (1 560,2 km^2, 140 unità amministrative tra comuni e municipi, 5 040 celle, 4,78 $MtCO_2$ anno^{-1}) la centrale di Turbigo.

2.2 Dieci predittori derivati dall'Osservazione della Terra



Fig. 1. Stack dei dieci predittori di OT per Shanghai Pudong (A1–A5: morfologia urbana e attività antropica; B1–B5: copertura del suolo e paesaggio fisico); in ogni pannello, risoluzione nativa (sinistra) e griglia di modellazione (destra).

Dieci bande riferite al 2023 sono estratte da GEE (Tabella 1, Fig. 1) da cinque famiglie di prodotti di OT: Global Human Settlement Layer P2023A, con superficie edificata da compositi Sentinel-2 e Landsat e popolazione residente [8, 9]; ESA WorldCover v200, classificazione a 10 m di Sentinel-1 e Sentinel-2 [10]; Sentinel-5P TROPOMI [11]; Sentinel-2 L2A [12]; NASADEM [13]. L'NO_2 troposferico è la media annua del prodotto L3 OFFL; l'NDVI la mediana annua delle scene con nuvolosità ≤ 20 % e

maschera QA60; le classi WorldCover sono convertite in indicatori binari prima del ricampionamento bilineare, così che il valore ricampionato approssimi la quota areale della classe.

Tabella 1. Predittori di OT (riferimento 2023; WorldCover 2021) e profilo delle AOI: mediana tra zone delle mediane zonali; quota % dell'AOI per WorldCover; densità media per A3. Aggregazione a 1/120°: media, più massimo per A1–A3.

ID	Banda [unità del profilo]	Prodotto di OT (sensore)	Ris. nativa	Pudong	Milano
A1	built_frac [–]	GHS-BUILT-S P2023A (Sentinel-2, Landsat)	10 m	0,225	0,147
A2	built_nres_frac [–]	GHS-BUILT-S P2023A (non residenziale)	10 m	0,042	0,061
A3	pop_count [ab km^{-2}]	GHS-POP P2023A	100 m	7 027	2 851
A4	wc_built [%]	ESA WorldCover v200 (Sentinel-1/2)	10 m	49,3	29,6
A5	no2_trop [µmol m^{-2}]	Sentinel-5P TROPOMI, L3 OFFL	3,5×5,5 km	237,2	106,0
B1	ndvi [–]	Sentinel-2 L2A, mediana annua	10 m	0,318	0,488
B2	wc_tree [%]	ESA WorldCover v200 (Sentinel-1/2)	10 m	10,4	17,6
B3	wc_crop [%]	ESA WorldCover v200 (Sentinel-1/2)	10 m	25,2	35,8
B4	wc_water [%]	ESA WorldCover v200 (Sentinel-1/2)	10 m	3,5	0,9
B5	elevation [m s.l.m.]	NASADEM (SRTM rielaborato)	30 m	4,0	135,0

Le bande sono riproiettate sulla griglia ODIAC con *crsTransform* e fattore di scala 4: ogni cella è suddivisa in 16 sottopixel a 1/480° (232 m in latitudine; 200 m e 163 m in longitudine a Pudong e a Milano). L'addestramento avviene a 1/120° con un doppio operatore di aggregazione: media di blocco delle $K = 10$ bande e massimo di blocco delle $M = 3$ bande strutturali (built_frac, built_nres_frac, pop_count):

$$z_c = \left[\bar{x}_c^1, \ldots, \bar{x}_c^K, \max_{p \in P_c} x_p^{k_1}, \ldots, \max_{p \in P_c} x_p^{k_M}\right] \quad (1)$$

dove x_p^k è il valore della banda k nel pixel fine p e P_c l'insieme dei 16 pixel della cella c. Il massimo conserva il picco sub-cella che la media attenua; per l'NO_2, la cui impronta (3,5 × 5,5 km) supera la cella, non sarebbe informativo.

2.3 Random Forest con validazione incrociata a blocchi spaziali

Il campione contiene un'osservazione per cella ODIAC; il target y_c è troncato al 99,5° percentile e modellato come $\log(1 + y_c)$. Il Random Forest (scikit-learn 1.4 [14]; 3 variabili per nodo) è ottimizzato su 56 configurazioni (7 × 4 × 2 valori di max_depth tra 3 e 10, min_samples_leaf tra 10 e 30, n_estimators 200 e 300) con validazione incrociata a blocchi spaziali [15]: GroupKFold a cinque fold su blocchi di 8 × 8 celle (≈8 × 8 km), 1,45 volte il lato maggiore dell'impronta TROPOMI, così che un retrieval di NO_2 non cada sia nell'addestramento sia nel test (143 blocchi a Pudong, 84 a Milano). La configurazione selezionata massimizza R^2_{CV} con un vincolo sullo scarto train–CV:

$$\theta^* = \arg\max_{\theta} R^2_{\mathrm{CV}}(\theta), \qquad \Delta(\theta) = R^2_{\mathrm{train}}(\theta) - R^2_{\mathrm{CV}}(\theta) \leq \delta \tag{2}$$

con δ = 0,15 e metriche calcolate nello spazio log1p; nella Sez. 3 R^2 è ricalcolato nello spazio delle emissioni dopo retrotrasformazione. Come riferimento si valutano un predittore costante e un Random Forest sul solo built_frac medio, peso di allocazione corrente nella prassi di disaggregazione. L'importanza dei predittori è stimata con Mean Decrease Impurity (MDI) e per permutazione (20 ripetizioni) [16].

2.4 Ridistribuzione a 1/480° vincolata ai totali di cella ODIAC

In predizione il vettore di ogni pixel fine replica i valori di banda nelle posizioni di medie e massimi (il massimo su un pixel coincide con il pixel): è l'ipotesi operativa di invarianza di scala della relazione appresa a 1/120°. Il punteggio $s_p = \exp(T^{-1}\Sigma_t h_t(\mathbf{x}_p)) - 1$, con h_t il t-esimo dei T alberi, non è un'emissione: ne contano solo i rapporti entro la cella madre, che ripartiscono il totale ODIAC E_c:

$$e_p = \frac{s_p}{\sum_{k \in P_c} s_k} \cdot E_c, \qquad \sum_{p \in P_c} e_p = E_c \tag{3}$$

La massa è conservata per costruzione (residuo < 10^{-3} % in entrambe le aree). Un bootstrap a blocchi spaziali (50 repliche con riaddestramento) misura la dispersione delle quote di ridistribuzione, cioè la loro stabilità condizionata a ODIAC, di cui non propaga l'incertezza.

2.5 Emissioni pro capite zonali e classi di densità per città

Le statistiche zonali sono calcolate sul raster a 1/480° mascherato con il poligono dell'AOI, assegnando ogni pixel all'unità che ne contiene il centroide; l'emissione pro capite di zona è $e_z = \Sigma_{p \in z} e_p / N_z$, con N_z popolazione GHS-POP (escluse le zone con meno di 25 pixel di popolazione o 500 residenti). Le zone con e_z superiore a cinque volte la mediana cittadina sono classificate CO_2-OUTLIER; le restanti sono suddivise con i quartili Q25 e Q75 della densità di popolazione, calcolati per città, in DENSITY-HIGH, DENSITY-MID e DENSITY-LOW (25/50/25).

3 Risultati: abilità predittiva confrontabile, relazioni apprese divergenti

3.1 Prestazioni del modello

In validazione spaziale a blocchi il modello raggiunge R^2CV = 0,650 a Pudong e 0,666 a Milano, con scarti train–CV quasi identici (0,094 e 0,096): l'abilità predittiva è confrontabile nei due domini e in entrambe le città la configurazione selezionata rispetta il vincolo sullo scarto dell'Eq. (2). I modelli di riferimento permettono di leggere questi valori. Il predittore costante ha R^2CV negativo (−0,009 e −0,021), per cui la partizione

a blocchi non lascia segnale spaziale sfruttabile in modo banale. Il solo built_frac raggiunge 0,308 a Pudong e 0,167 a Milano, cioè meno della metà e circa un quarto dell'abilità dello stack completo. Il troncamento del target al 99,5° percentile è determinante: senza di esso R^2CV scende a 0,185 e 0,296.

3.2 Gerarchia dei predittori RF: Feature e Permutation Importance

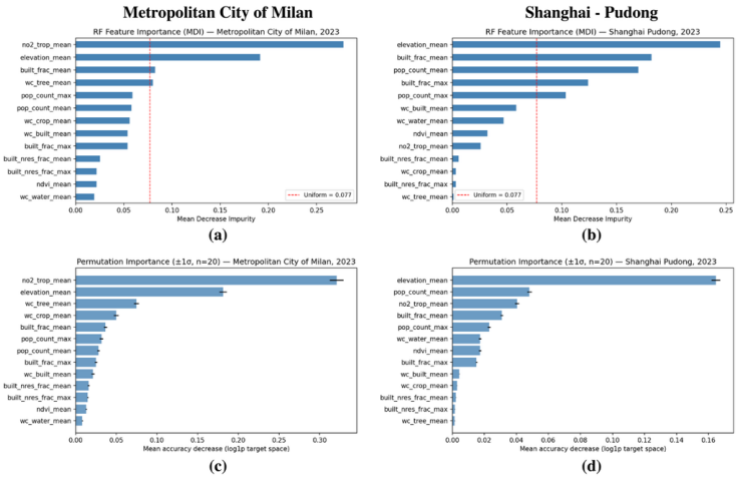

Fig. 2. Importanza dei predittori, Milano (sinistra) e Shanghai Pudong (destra): MDI (a–b) e permutazione in spazio log1p, 20 ripetizioni (c–d); tratteggio: riferimento uniforme 1/13.

Le gerarchie apprese divergono (Fig. 2). A Milano domina l'NO_2 troposferico (MDI 0,278; permutazione 0,321), seguito dalla quota (0,191; 0,181). A Pudong domina la quota (MDI 0,244; permutazione 0,165), seguita per MDI da built_frac (0,182) e pop_count (0,170); l'NO_2 è nono per MDI (0,026) e terzo per permutazione (0,040). Il predittore dominante è lo stesso con entrambe le metriche: il contrasto non è un artefatto dell'MDI. Il profilo di OT (Tabella 1) ne mostra i gradienti: a Pudong quota mediana di 4 m (escursione 33 m) e colonna di NO_2 2,2 volte quella milanese; a Milano escursione di 205 m, NDVI e seminativo più estesi.

3.3 Hotspot costiero-industriale a Pudong, struttura monocentrica a Milano

Nelle superfici ridistribuite (Fig. 3), a Pudong (P5–P95: 36–3 382 tCO_2 $pixel^{-1}$ $anno^{-1}$) il cluster di massima emissione occupa il settore nord-occidentale, in corrispondenza del complesso industriale-portuale di Waigaoqiao, su un'estensione inferiore a quella di qualsiasi jiedao, e decresce verso l'interno agricolo meridionale. A Milano (P5–P95: 6–232 tCO_2 $pixel^{-1}$ $anno^{-1}$) la struttura è monocentrica, con massimo nel capoluogo, decadimento radiale verso la pianura e un hotspot isolato a ovest in corrispondenza della centrale di Turbigo. Normalizzate per la popolazione (Fig. 3c–d), le superfici si frammentano in massimi locali su un fondo basso.

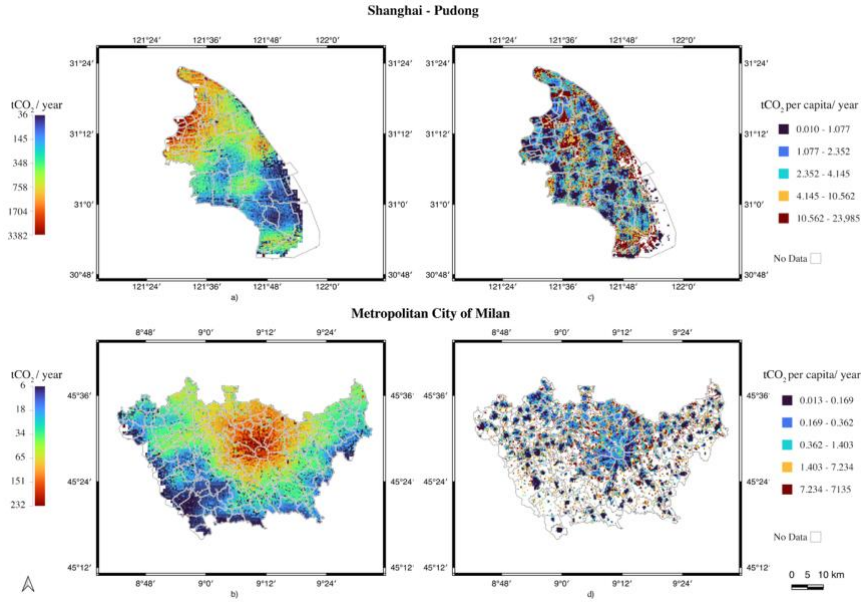

Fig. 3. Emissioni ridistribuite a 1/480° da ODIAC 2023 (release 2024), Pudong in alto e Milano in basso: totali (a–b, tCO_2 $pixel^{-1}$ $anno^{-1}$; tacche al 5°, 25°, 50°, 75°, 95° percentile) e pro capite (c–d, tCO_2 ab^{-1} $anno^{-1}$; pixel diviso per la popolazione GHS-POP co-localizzata).

3.4 Divario pro capite Pudong–Milano a parità di densità

A Pudong 35 jiedao hanno popolazione valida (esclusa Nánhuì Xīnchéng, priva di popolazione in GHS-POP): Gāodōng, coincidente con il cluster di Waigaoqiao, è CO_2-OUTLIER e le altre 34 zone sono stratificate in 9/16/9. A Milano i CO_2-OUTLIER sono 4 (Turbigo, sorgente puntuale, e tre comuni rurali con denominatore demografico ridotto) e 136 unità sono stratificate in 34/68/34. La mediana pro capite di zona è 1,560 tCO_2 ab^{-1} $anno^{-1}$ a Pudong e 0,571 a Milano (rapporto 2,73×), ma l'intervallo interquartile della densità di Pudong è un ordine di grandezza più ampio (Tabella 2): il rapporto aggregato confonde composizione e intensità. A parità di classe il rapporto resta superiore a uno ma varia da 1,98× (DENSITY-LOW) a 3,06× (DENSITY-MID), con intervalli bootstrap non sovrapposti (CV mediano delle quote di ridistribuzione: 0,158 a Pudong, 0,081 a Milano). A Milano l'emissione pro capite decresce al crescere della densità (0,802 → 0,571 → 0,389); a Pudong la classe intermedia (1,749) supera sia la bassa (1,586) sia l'alta (1,117).

Tabella 2. Emissioni pro capite di zona per classe (tCO_2 ab^{-1} $anno^{-1}$; mediana [IQR] tra zone). Soglie Q25/Q75 della densità: 3 898/27 465 ab km^{-2} (Pudong), 982/3 494 ab km^{-2} (Milano). Intervallo del rapporto: 5°–95° percentile del bootstrap a blocchi spaziali.

Classe	n PD	n MI	Pudong	Milano	PD/MI [5–95 %]
DENSITY-HIGH	9	34	1,117 [0,915–1,222]	0,389 [0,279–0,481]	2,87× [2,84–2,91]
DENSITY-MID	16	68	1,749 [1,270–2,761]	0,571 [0,436–0,790]	3,06× [3,02–3,10]
DENSITY-LOW	9	34	1,586 [1,521–2,712]	0,802 [0,606–1,039]	1,98× [1,96–2,01]
CO_2-OUTLIER	1	4	31,875	5,817 [3,049–18,627]	5,48× [5,35–5,66]

4 Conclusioni, limiti e sviluppi

A configurazione fissa le due città ottengono abilità predittiva confrontabile attraverso relazioni diverse: a Milano la ridistribuzione è guidata dall'NO_2, coerente con un regime di combustione diffusa dominato dai trasporti; a Pudong dalla quota, espressione spaziale della concentrazione di infrastrutture energetiche e industriali nella fascia costiera bassa, che ODIAC contabilizza come emissione territoriale diretta. Come per i modelli basati sulle luci notturne, i cui coefficienti risultano specifici della città [6], la procedura è trasferibile, i pesi appresi no: il confronto dell'importanza dei predittori tra siti a configurazione fissa è una diagnostica di trasferibilità che non richiede dati di riferimento ad alta risoluzione.

I limiti sono quattro. (1) La validazione opera alla risoluzione di addestramento: in assenza di riferimenti osservativi sub-chilometrici di CO_2 antropica, il prodotto a 1/480° è un prior spazialmente raffinato di ODIAC, non una mappa validata in modo indipendente, e il bootstrap ne misura la stabilità, non l'accuratezza [17]. (2) Il prodotto eredita ambito settoriale, anno ed errori di allocazione di ODIAC ed esclude le emissioni indirette da consumo elettrico. (3) Il predittore dominante a Milano è il più grossolano: l'impronta NO_2 TROPOMI è circa quattro volte la dimensione lineare della cella di addestramento. (4) La stabilità interannuale delle relazioni apprese non è verificata. La pipeline, basata solo su prodotti di OT globali in GEE, è aggiornabile a ogni release di ODIAC.

Nel modello proposto il vincolo principale resta l'inventario di partenza, non la procedura di apprendimento: questa può essere riaddestrata a ogni nuova release di ODIAC e per ogni nuova città, mentre la qualità della ridistribuzione resta limitata da quella del target globale. Lo sviluppo naturale è integrare nel target dati emissivi e misure a scala locale, che renderebbero possibile anche la validazione indipendente a scala sub-chilometrica oggi assente.

Riferimenti bibliografici

1. Oda, T., Maksyutov, S.: A very high-resolution (1 km × 1 km) global fossil fuel CO_2 emission inventory derived using a point source database and satellite observations of nighttime lights. Atmospheric Chemistry and Physics 11, 543–556 (2011).
2. Oda, T., Maksyutov, S., Andres, R.J.: The Open-source Data Inventory for Anthropogenic CO_2, version 2016 (ODIAC2016): a global monthly fossil fuel CO_2 gridded emissions data product for tracer transport simulations and surface flux inversions. Earth System Science Data 10, 87–107 (2018).
3. Wang, R., Zhang, Y., Zhao, S., Wang, X.: Open-data-based city-scale gridded carbon dioxide emission inventory: supporting urban carbon monitoring in Chengdu, China. Carbon Footprints 3, 14 (2024).
4. Cui, L., Yang, H., Martin, M., et al.: Mapping high-resolution carbon emission spatial distribution combined with carbon satellite and multi-source data. Remote Sensing 17(17), 3125 (2025).
5. Zhang, Y., Liu, X., Lei, L., Liu, L.: Estimating global anthropogenic CO_2 gridded emissions using a data-driven stacked random forest regression model. Remote Sensing 14, 3899 (2022).
6. Han, J., Meng, X., Liang, H., et al.: An improved nightlight-based method for modeling urban CO_2 emissions. Environmental Modelling & Software 107, 307–320 (2018).
7. Gorelick, N., Hancher, M., Dixon, M., et al.: Google Earth Engine: planetary-scale geospatial analysis for everyone. Remote Sensing of Environment 202, 18–27 (2017).
8. Pesaresi, M., Schiavina, M., Politis, P., et al.: Advances on the Global Human Settlement Layer by joint assessment of Earth Observation and population survey data. International Journal of Digital Earth 17, 2390454 (2024).
9. Schiavina, M., Freire, S., Carioli, A., MacManus, K.: GHS-POP R2023A – GHS population grid multitemporal (1975–2030) [dataset]. European Commission, Joint Research Centre (2023).
10. Zanaga, D., Van De Kerchove, R., Daems, D., et al.: ESA WorldCover 10 m 2021 v200 [dataset]. Zenodo (2022).
11. Veefkind, J.P., Aben, I., McMullan, K., et al.: TROPOMI on the ESA Sentinel-5 Precursor: a GMES mission for global observations of the atmospheric composition for climate, air quality and ozone layer applications. Remote Sensing of Environment 120, 70–83 (2012).
12. Drusch, M., Del Bello, U., Carlier, S., et al.: Sentinel-2: ESA's optical high-resolution mission for GMES operational services. Remote Sensing of Environment 120, 25–36 (2012).
13. Crippen, R., Buckley, S., Agram, P., et al.: NASADEM global elevation model: methods and progress. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences XLI-B4, 125–128 (2016).
14. Pedregosa, F., Varoquaux, G., Gramfort, A., et al.: Scikit-learn: machine learning in Python. Journal of Machine Learning Research 12, 2825–2830 (2011).
15. Roberts, D.R., Bahn, V., Ciuti, S., et al.: Cross-validation strategies for data with temporal, spatial, hierarchical, or phylogenetic structure. Ecography 40, 913–929 (2017).
16. Strobl, C., Boulesteix, A.-L., Kneib, T., Augustin, T., Zeileis, A.: Conditional variable importance for random forests. BMC Bioinformatics 9, 307 (2008).
17. Gurney, K.R., Liang, J., O'Keeffe, D., et al.: Comparison of global downscaled versus bottom-up fossil fuel CO_2 emissions at the urban scale in four U.S. urban areas. Journal of Geophysical Research: Atmospheres 124, 2823–2840 (2019).