

Verwenden der Gradientenverstärkungsregression zur Verbesserung der Vorhersagen des Umgebungssonnenwindmodells

RL Bailey, MA Reiß, CN Arge, C. Möstl, C. J. Henney, MJ Owens, UV Amerstorfer, T. Amerstorfer, AJ Weiss, J. Hinterreiter
Erstmals veröffentlicht: 24. April 2021

<https://doi.org/10.1029/2020SW002673>

Zitate: 4

Die Untersuchung des umgebenden Sonnenwinds, eines kontinuierlichen, druckgetriebenen Plasmastroms, der von unserer Sonne ausgeht, ist ein wichtiger Bestandteil der Weltraumwetterforschung. Die umgebenden Sonnenwindströmungen im interplanetaren Raum bestimmen, wie sich Sonnenstürme durch die Heliosphäre entwickeln, bevor sie die Erde erreichen, und sind insbesondere während des Sonnenminimums selbst ein Treiber der Aktivität im Erdmagnetfeld. Die genaue Vorhersage des umgebenden Sonnenwindflusses ist daher für das Weltraumwetterbewusstsein unerlässlich. Hier stellen wir einen maschinellen Lernansatz vor, bei dem Lösungen aus magnetischen Modellen der Sonnenkorona verwendet werden, um die Sonnenwindbedingungen in der Nähe der Erde auszugeben. Die Ergebnisse werden in einer umfassenden Validierungsanalyse mit Beobachtungen und bestehenden Modellen verglichen, und das neue Modell übertrifft bestehende Modelle in fast allen Maßen. Zusätzlich, Dieser Ansatz bietet eine neue Perspektive, um die Rolle verschiedener Eingabedaten für die Umgebungssonnenwindmodellierung zu diskutieren und was uns dies über die zugrunde liegenden physikalischen Prozesse sagt. Das hier diskutierte endgültige Modell stellt einen extrem schnellen, gut validierten und Open-Source-Ansatz für die Vorhersage des Umgebungssonnenwinds auf der Erde dar.

Wichtige Punkte

- Wir stellen einen maschinellen Lernansatz vor, der anstelle des Wang-Sheeley-Arge (WSA)-Modells zur Vorhersage der Sonnenwindgeschwindigkeit in der Nähe der Erde verwendet werden kann
- Das Tool wird für einen ganzen Sonnenzyklus validiert und übertrifft etablierte Modelle und ein grundlegendes Wiederholungsmodell

- Diese Studie stellt einen schnellen und gut validierten Open-Source-Beitrag auf dem Gebiet der Umgebungssonnenwindmodellierung und -vorhersage dar

1. Einleitung

Erst in den 1970er Jahren wurden durch Röntgenteleskope des NASA-Satelliten Skylab die dunklen Flecken in den Polarregionen der Sonne als koronale Löcher identifiziert. In den vergangenen Jahrzehnten hat sich herausgestellt, dass es sich um Bereiche offener Magnetfeldlinien handelt, entlang derer das Sonnenplasma, das die Sonne in einem kontinuierlichen Fluss verlässt, auf Überschallgeschwindigkeit in die Weiten unseres Sonnensystems beschleunigt wird. Diese schnelle Komponente des umgebenden Sonnenwindflusses und das darin eingebettete Magnetfeld rotieren gemeinsam mit der Sonne in einer sich ständig erweiternden Spirale, der Parker-Spirale. Das Verständnis des umgebenden Sonnenwinds ist wichtig für die Weltraumwettervorhersage, um die Entwicklung und mögliche Auswirkungen von Sonnenstürmen zu bestimmen, insbesondere da sie die Entwicklung vorübergehender Ereignisse wie koronaler Massenauswürfe (CMEs) beeinflussen. [2013](#) ; Temmer et al., [2011](#)). Umgebungssonnenwindströmungen sind selbst auch ein wichtiger Treiber wiederkehrender geomagnetischer Aktivität auf der Erde (Nakagawa et al., [2019](#) ; Verbanac et al., [2011](#) ; Zhang et al., [2007](#)), die kritische Eigenschaften im interplanetaren Raum wie den Sonnenwind bestimmen Geschwindigkeit, Magnetfeldstärke und Orientierung (Luhmann et al., [2002](#)). Ein klares Bild sowie das Verständnis und die genaue Modellierung des umgebenden Sonnenwinds sind daher in allen Aspekten der Weltraumwetterforschung unerlässlich.

Bei den heutigen Ansätzen zur Modellierung des umgebenden Sonnenwinds werden die Sonnenoberfläche, die Korona und die innere Heliosphäre als verbundenes System behandelt, um die Dynamik des umgebenden Sonnenwindflusses von der Sonne in die Nähe der Erde zu simulieren. Diese gekoppelten Modellierungsansätze umfassen üblicherweise den Bereich von einem Sonnenradius (R_{\odot}) bis zur Erde bei 1 AE, wobei das koronale Modell von $1 R_{\odot}$ bis $5 R_{\odot}$ (oder $30 R_{\odot}$) und das Heliosphärenmodell den Bereich von $5-30 R_{\odot}$ bis 1 AU. Trotz der Entdeckung einer empirischen Beziehung zwischen der Konfiguration offener Magnetfeldlinien auf der Sonne und den Eigenschaften des Sonnenwinds, gemessen am Sonne-Erde-Lagrange-Punkt 1 (L1) in der Nähe der Erde (Wang & Sheeley, 1990), erweist sie sich immer noch [als](#) herausfordernd Entwicklung und Optimierung empirischer Techniken zur Bestimmung der Sonnenwindbedingungen an der inneren Grenze des heliosphärischen Bereichs (Arge & Pizzo, [2000](#) ; Arge et al., [2004](#) ; Riley et al., [2001](#)). Bekannte empirische Zusammenhänge in diesem Zusammenhang sind das Wang-Sheeley (WS)-Modell (Wang & Sheeley, [1990](#)), das Distance from the Coronal Hole Boundary (DCHB)-Modell (Riley et al., [2001](#)), und das Wang-Sheeley-Arge (WSA)-Modell (Arge et al., [2003](#)). Anspruchsvollere dreidimensionale magnetohydrodynamische (MHD) Codes wie CORHEL (Linker et al., [2016](#)), LFM-Helio (Merkin et al., [2016](#)), SIP-CESE (Feng et al., [2015](#)) und COIN-TVD MHD (Shen et al., [2018](#)) werden ebenfalls verwendet, wobei weitere Beispiele der Magnetohydrodynamics Algorithm outside a Sphere (Linker et al., [1999](#)), Enlil (Odstrcil, [2003](#)), das Space Weather Modeling Framework (Tóth et al., [2005](#)) und das kürzlich entwickelte European Heliospheric Forecasting Information Asset (Pomoell & Poedts, [2018](#)). Neben diesen MHD-Modellen wurden auch andere Modellierungsansätze entwickelt, die auf empirischen Zusammenhängen und Statistiken basieren (z. B. M. Owens, Lang, et al., [2020](#)). In der Welt des maschinellen Lernens entwickelten frühe Arbeiten von Wintoft und Lundstedt ([1997](#)) und Wintoft und Lundstedt ([1999](#)) neuronale Netze zur Vorhersage der Sonnenwindgeschwindigkeit in der Nähe der

Erde unter Verwendung von Werten aus koronalen magnetischen Modellen, und ähnliche Ideen wurden von Liu et al. weiterentwickelt Al. ([2011](#)), Yanget al. ([2018](#)) und Chandorkar et al. ([2020](#)).

Von den verfügbaren Modellen erfreut sich der WSA-Modellansatz einer weit verbreiteten Anwendung in betrieblichen Umgebungen im Met Office und im Space Weather Prediction Center der NOAA, hauptsächlich bei der Vorhersage von Hochgeschwindigkeits-Sonnenwindströmen (MacNeice, 2009a; Owens et al. , 2005 ; Reiss et al., [2016](#) , [2019](#)). Es hat auch Anwendungen für viele verschiedene wissenschaftliche Probleme wie die Entwicklung von CMEs im interplanetaren Raum und ihre anschließende Ankunft auf der Erde (Mays et al., [2015](#) ; Riley et al., [2018](#) ; Scolini et al., [2019](#) ; Taktakishvili et al. , [2009](#) ; Verbeke et al., [2019](#) ; Wold et al., [2018](#)). Vorhersagen von solarenergetischen Teilchenereignissen (Luhmann et al., [2017](#) ; MacNeice et al., [2011](#)) und Studien zur Bewertung der Wechselwirkung zwischen Sonnenwind und planetaren Magnetosphären (Dewey et al., [2015](#)) wurden ebenfalls mit dem WSA-Modell durchgeführt , was seine Bedeutung in der aktuellen Forschung hervorhebt.

Trotz aller jüngsten Entwicklungen übertreffen Modelle zur Vorhersage des Umgebungs-Sonnenwinds die 27-tägige Persistenz des Sonnenwinds immer noch nur geringfügig, oft mit Unsicherheiten im Timing von Hochgeschwindigkeitsströmen von etwa einem Tag (Allen et al., 2020; [Devos et al., 2014](#) ; Hinterreiter et al., [2019](#) ; Jian et al., [2011](#) ; Kohutova et al., [2016](#) ; Owens et al., [2008](#) , [2013](#) ; Reiss et al., [2016](#)). Eine große Unsicherheitsquelle liegt in der Modellierung der Topologie des koronalen Magnetfelds, die das WSA-Modell als Eingabe verwendet, da wir normalerweise nur Daten für eine Seite der Sonne haben. [Dies wird auf eine Weise unter Verwendung des Air Force Data Assimilative Photospheric Flux Transport- oder ADAPT-Modells \(Arge et al., 2010](#) ; Henney et al., [2012](#) ; Hickmann et al., [2015](#)) angegangen , das mehrere Realisierungen des möglichen Magnetfelds bietet auf der anderen Seite der Sonne. Wie aus den vielen und unterschiedlichen Ansätzen ersichtlich ist, bleibt die Vorhersage der umgebenden Sonnenwindbedingungen eine Herausforderung.

Weitere Anstrengungen sind erforderlich, um unsere Fähigkeiten zur Vorhersage von Bedingungen im umgebenden Sonnenwind zu verbessern. Hier verbessern wir Vorhersagen des umgebenden Sonnenwinds, indem wir Techniken des maschinellen Lernens mit Modellierungsergebnissen aus der äußeren Randbedingung von koronalen magnetischen Modellen koppeln. Techniken des maschinellen Lernens erleben eine Renaissance und werden sowohl in der Öffentlichkeit als auch in der Weltraumwettergemeinschaft als neues Werkzeug für aktuelle Herausforderungen immer beliebter, mit vielversprechenden Ergebnissen. Eine Übersicht über aktuelle Entwicklungen maschineller Lernverfahren zu den Themen Weltraumwetter und Heliosphäre findet sich beispielsweise in Camporeale ([2019](#)), mit Studien, die sich mit Problemen wie der Vorhersage geomagnetischer Indizes und der automatisierten Klassifizierung von Sonnenbildern befassen. Bisher gab es jedoch neben der Anwendung statistischer Techniken (Bussy-Virat & Ridley, [2014](#) ; Riley et al., [2017](#)) nur wenige Studien zur Vorhersage des Umgebungssonnenwinds mithilfe von maschinellem Lernen. Hier werden wir maschinelles Lernen mit etablierten Sonnenwindmethoden in Kombination mit dem ADAPT-Output koppeln. ADAPT produziert ein Ensemble von Lösungen, aber es fehlen noch Strategien, wie diese Ensembles am besten kombiniert werden können. Maschinelles Lernen bietet eine interessante Möglichkeit, Wege zu finden, magnetische Kartenlösungen optimal zu kombinieren, um die Forschung in die betriebliche Nutzung zu überführen.

Die maschinelle Lernmethode, die wir in dieser Studie anwenden, ist ein Gradient Boosting Regressor (GBR), eine leistungsstarke Technik, die einen einzelnen Schätzer aus einer Sammlung schwacher Lerner, den so genannten Entscheidungsbäumen, erstellt (Friedman, 2001 [2](#)). Wir verwenden den GBR, um die Massengeschwindigkeit des umgebenden Sonnenwinds auf der Erde vorherzusagen, indem wir die magnetischen Topologielösungen an der äußeren Grenze des koronalen magnetischen Modells verwenden. Abbildung [1](#) zeigt eine Darstellung der WSA-Koronalmodelllösungen für eine Carrington-Rotation und die für das Modelltraining extrahierten Variablen. Der obere Teil stellt Karten des Ausdehnungsfaktors f_p der Flussröhre und des Abstands zur koronalen Lochgrenze d dar, berechnet bei einer Referenzhöhe von $5 R_\odot$. Der untere Teil zeigt jede aus der Karte extrahierte Variable entlang der Bahn unter der Erde, die der Weg ist, entlang dem eine Projektion der Erde während der Carrington-Rotation verläuft. Alle 12 ADAPT-Realisierungen können in den maschinellen Lernansatz aufgenommen werden, um Unsicherheiten in der magnetischen Modellierung zu berücksichtigen. Obwohl der Fokus auf der Verbesserung der Modellierungsfähigkeiten liegt, werden wir zeigen, dass wir durch das Training unseres Modells die grundlegenden Eigenschaften von Sonnenwindmodellen untersuchen können, was Hinweise auf die zugrunde liegenden physikalischen Mechanismen liefert, die für die Beschleunigung des Sonnenwinds verantwortlich sind.




Abbildung 1

[Im Abbildungsbetrachter öffnen](#)[Steckdose](#)

Der Ausdehnungsfaktor des Flussrohrs f_p (links) und der Abstand zur koronalen Lochgrenze d (rechts) sind für eine Carrington-Rotation (CR #2052) gezeigt. (a–b) Koronale Modellkarten für jede Variable an der äußeren Grenze des koronalen Modells ($5 R_\odot$) mit der subdiskalen Spur, die mit einer gestrichelten weißen Linie eingezeichnet ist. (c–d) Die Werte, die entlang der Spur unter der Erde extrahiert wurden. Die Ausgabe aller 12 ADAPT-Realisierungen wird in Farbe angezeigt, während die schwarze Linie den Mittelwert darstellt. Das Protokoll von f_p dargestellt, damit das Verhalten im Plot besser interpretierbar ist, der Wert musste aber für das Modelltraining nicht skaliert werden. Beachten Sie, dass die Zeit aus zeitlicher Sicht mit abnehmendem Carrington-Längengrad in die entgegengesetzte Richtung läuft, wenn sich die Sonne gemäß der Karte von links nach rechts dreht. ADAPT, Air Force Data Assimilative Photospheric Flux Transport.

Wir präsentieren die Anwendung von Techniken des maschinellen Lernens, um etablierte Ansätze zur Sonnenwindmodellierung zu ergänzen und zu informieren. Das maschinelle Lernmodell wird auf 14 Jahre vergangener Daten (1992 bis 2006) trainiert und auf einer vollen Sonnenzykluslänge von 11 Jahren (2006 bis 2017) aus dem jüngsten Sonnenzyklus 24

getestet. Wir präsentieren eine umfassende Validierungsanalyse des maschinellen Lernens (GBR)-Modelllösungen und vergleichen Sie die Ergebnisse mit häufig angewandten Umgebungssonnenwindmodellen und Referenzbasismodellen, einschließlich eines 27-Tage-Persistenzmodells, das die Annäherung verwendet, dass sich die Bedingungen in der Umgebungssonnenwindströmung nach jeder Carrington-Rotation wiederholen. Daran schließt sich eine Diskussion über die Bedeutung an, um anschließend mögliche zukünftige Untersuchungen zu skizzieren.

2 Methoden

Magnetische Modelle der Sonne

In diesem Abschnitt präsentieren wir den numerischen Rahmen zur Rekonstruktion der globalen Magnetfeldtopologie in der Sonnenkorona. Unser Framework stützt sich auf magnetische Karten des photosphärischen Magnetfelds der Global Oscillation Network Group des National Solar Observatory. Insbesondere verwenden wir das ADAPT-Modell (Arge et al., [2010](#); Henney et al., [2012](#); Hickmann et al., [2015](#)). ADAPT ist ein Flusstransportmodell (das z. B. differentielle Rotation und meridionale Flüsse umfasst), um ein Ensemble von Schätzungen der globalen räumlichen Verteilung des solaren photosphärischen Magnetfelds bereitzustellen. Das ADAPT-Modell produzierte Ensembles von 12 Realisierungen, die die durch Supergranulation verursachte Unsicherheit darstellen (Worden & Harvey, [2000](#)), was bedeutet, dass jede ADAPT-Realisierung eine etwas andere Magnetfeldkonfiguration darstellt, abhängig von den Annahmen, die für das Magnetfeld auf der anderen Seite der Sonne getroffen werden.

Basierend auf den 12 verschiedenen ADAPT-Realisierungen rekonstruieren wir die globale koronale Magnetfeldtopologie unter Verwendung der allgemein verwendeten Potential Field Source Surface (PFSS; Altschuler & Newkirk, [1969](#); Schatten et al., [1969](#)) und Schatten Current Sheet (SCS; Schatten, [1971](#)) Modellkombination. Das etablierte PFSS-Modell berechnet die potentielle Magnetfeldlösung in der Sonnenkorona mit einer äußeren Randbedingung, dass das Magnetfeld an der Quellenoberfläche bei $2,5 R_{\odot}$ rein radial ist. Das SCS-Modell im Modellbereich zwischen $2,5$ und $5 R_{\odot}$ berücksichtigt die Breiteninvarianz des radialen Felds, wie es von der Ulysses-Mission beobachtet wurde (Wang & Sheeley, [1995](#)).

Aus der modellierten globalen Magnetfeldkonfiguration berechnen wir magnetische Eigenschaften wie den Flächenausdehnungsfaktor und den Abstand zur koronalen Lochgrenze. Der Flächenausdehnungsfaktor f_p ist die Rate, mit der sich die Flussröhre zwischen der Photosphäre und einer Referenzhöhe in der Korona ausdehnt (Wang & Sheeley, [1990](#)):

$$f_p = \left(\frac{R_{\odot}}{2.5 R_{\odot}} \right)^2 \frac{|\mathbf{B}(R_{\odot}, \theta_0, \phi_0)|}{|\mathbf{B}(2.5 R_{\odot}, \theta_1, \phi_1)|} \quad (1)$$

θ ist die Länge und ϕ die Breite, wobei die Indizes 0 und 1 die Länge/Breite an der Sonnenoberfläche bzw. $2,5$ Sonnenradien darstellen. Wir verfolgen die Feldlinien von $5 R_{\odot}$ nach unten und berechnen dann den Flussröhren-Ausdehnungsfaktor zwischen $2,5 R_{\odot}$ und der Sonnenoberfläche gemäß der Definition von Wang und Sheeley ([1990](#)). Der Abstand zur koronalen Lochgrenze d bezieht sich auf den Großkreisabstand, den ein Freifeld-Fußpunkt in der Photosphäre von der nächsten koronalen Lochgrenze entfernt liegt. Er wird am Fußpunkt der Feldlinie auf der Sonnenoberfläche berechnet und dieser Wert

dann entlang des Magnetfeldes bis zu einem Abstand von $5 R_{\odot}$ abgebildet. Die zugrunde liegende Idee von d ist, dass der Sonnenwind in der Nähe von koronalen Lochgrenzen langsam und innerhalb von Regionen mit offener Feldtopologie schnell ist (Riley et al., [2001](#)).

Aus den Gesamtlösungen von ADAPT erhalten wir einen Satz von 12 verschiedenen Ergebnissen für alle berechneten magnetischen Eigenschaften. Neben dem Expansionsfaktor und dem Abstand zur nächsten koronalen Lochgrenze am Punkt unter der Erde untersuchen wir auch die Nützlichkeit der Magnetfeldstärke am photosphärischen Fußpunkt, B_{phot} , und der äußeren Grenze des koronalen Modells, B_{cor} .

Als Referenzbasismodell verwenden wir den traditionellen WSA-Ansatz (Arge et al., [2003](#)) zur Spezifikation der Bedingungen im sonnennahen Sonnenwind. Das hier verwendete WSA-Modell ist eine Kombination aus dem Expansionsfaktor und dem Abstand von der nächsten koronalen Lochgrenze. Insbesondere ist die in dieser Studie verwendete WSA-Beziehung gegeben durch

$$v_{\text{wsa}}(f_p, d) = c_1 + \frac{c_2}{(1 + f_p)^{c_3}} \left\{ c_4 - c_5 \exp \left[- \left(\frac{d}{c_6} \right)^{c_7} \right] \right\}^{c_8}, \quad (2)$$

wobei c_i die Modellkoeffizienten sind, für die wir die folgenden Einstellungen verwenden: $c_1 = 250 \text{ km s}^{-1}$, $c_2 = 650 \text{ km s}^{-1}$, $c_3 = 0,19$, $c_4 = 1$, $c_5 = 0,8$, $c_6 = 3^\circ$, $c_7 = 1,75$ und $c_8 = 3$ (Arge et al., [2003](#)).

Um die Sonnenwindlösungen nahe der Sonne zur Erde abzubilden, verwenden wir das Heliospheric Upwind eXtrapolation-Modell (HUX, Riley & Lionello, [2011](#)), das die Flüssigkeitsimpulsgleichung so weit wie möglich vereinfacht. Darüber hinaus passen die HUX-Modelllösungen ziemlich gut zu der dynamischen Entwicklung, die von globalen heliosphärischen MHD-Codes erforscht wird, während sie geringe Rechenanforderungen haben (M. Owens, Lang, et al., 2020). Auf diese Weise können wir die Ergebnisse und Implikationen der Ensemble-ADAPT-Realisierungen effizient untersuchen. Für weitere Details zum HUX-Modell möchten wir den Leser auf Riley und Lionello ([2011](#)) und Owens et al. verweisen. ([2017](#)).

Anwendung des maschinellen Lernens

Wir verwenden einen maschinellen Lernansatz, um die Sonnenwindgeschwindigkeit bei L1 aus der Ausgabe des koronalen magnetischen Modells vorherzusagen. Die durchgearbeiteten Schritte zum Trainieren und Fertigstellen des maschinellen Lernmodells können wie folgt zusammengefasst werden. Zunächst die Daten bei einer Höhe von $5 R_{\odot}$ wird aus dem koronalen magnetischen Modell entlang der Spur unter der Erde extrahiert, um eine Zeitreihe zu erstellen. Als nächstes wird dieser Datensatz in Trainings- und Testdaten aufgeteilt, wobei 14,5 Jahre verwendet werden, um das Modell zu trainieren, und eine volle Sonnenzykluslänge (11 Jahre) übrig bleibt, um das Modell zu testen. Das Modell, das trainiert wird, ist ein GBR, und ein anfängliches iteratives Training durch Sätze von für maschinelles Lernen spezifischen Parametern wird am Datensatz durchgeführt, um diejenigen zu bestimmen, die für dieses spezifische Problem am besten geeignet sind. Mit den ermittelten Modellparametern wird das Modell zunächst mit dem vollständigen Datensatz trainiert, bevor eine Merkmalsauswahl durchgeführt wird, um die Anzahl der Eingabemerkmale zu reduzieren. Dadurch entsteht eine Reihe von trainierten Modellen, die wir anhand von Validierungsmetriken vergleichen. Das optimale Modell wird zur späteren Verwendung gespeichert.

Die aus dem Koronalmagnetmodell extrahierten Ergebnisse sind die Eigenschaften f_p , d , B_{cor} und B_{phot} berechnet entlang der Bahn unter der Erde, dh dem Weg, den die Erde durch die Rotation verfolgt, die entlang der Sonnenoberfläche projiziert wird. Es gab 12 koronale magnetische Modelllösungen pro Tag basierend auf 12 verschiedenen ADAPT-Lösungen. Die Sub-Earth-Spur wurde aus jedem davon extrahiert, und alle ADAPT-Lösungen wurden eingeschlossen. Die Daten wurden in einer Weise extrahiert, die einer Betriebsumgebung entspricht, in der die Zeitreihe einmal täglich mit den neuesten Ergebnissen des koronalen Magnetmodells aktualisiert wird (dies entspricht 6–7 Zeitschritten pro Tag). Um die Modelllösungen mit Beobachtungen zu vergleichen, wurden die aufgrund unterschiedlicher Carrington-Rotationslängen nicht periodischen Sonnenwindlösungen auf periodische Zeitstempel entsprechend einer Längsauflösung von 2° (3,64 h) interpoliert. Abbildung 1 zeigt die vollständigen koronalen Modellkarten und einen Pfad, der entlang der Spur unter der Erde extrahiert wurde, während Abbildung 3 beide Variablen zeigt, die extrahiert wurden, um eine Zeitreihe zu bilden.

In der Sprache des maschinellen Lernens sind die Merkmale die oben beschriebenen Eigenschaften des magnetischen Modells, und das Ziel ist die Sonnenwindgeschwindigkeit v_{sw} in der erdnahen Umgebung. Das Modell wird so trainiert, dass es das Ziel aus jedem gegebenen Satz von Merkmalen erzeugen kann. Die Sonnenwindgeschwindigkeit wird dem stündlichen OMNI-Datensatz entnommen. In Modellen, die zur Vorhersage der umgebenden Sonnenwindgeschwindigkeit aus magnetischen Modellergebnissen entwickelt wurden, gibt es normalerweise ein Heliosphärenmodell, um die Expansionszeiten von der äußeren Grenze des koronalen Modells bis L1 zu berücksichtigen.

Bei diesem Ansatz wird die Verwendung einer einzelnen definierten Zeitverschiebung vermieden und stattdessen die Variablen der letzten 2–6 Tage als Eingabe genommen, was bedeutet, dass bei einer Auflösung von 3,64 h 29 zeitverschobene Werte von vier Eigenschaften genommen werden aus 12 möglichen ADAPT-Realisierungen, was zu insgesamt 1.392 magnetischen Modellmerkmalen führt. Zusätzlich zu den magnetischen Eigenschaften ist eine Variable für die Persistenz der Massengeschwindigkeit des Sonnenwinds, v_{Pers} , wurde unter der Annahme aufgenommen, dass sich die Variation der Sonnenwindgeschwindigkeit alle 27,27 Tage wiederholt. Drei Persistenzmerkmale wurden aufgenommen: Die Sonnenwindgeschwindigkeit 26, 27 und 28 Tage vor der Zielvorhersage, insgesamt 1.395 Merkmale. Im Gegensatz zu vielen anderen Machine-Learning-Ansätzen müssen die Features für einen GBR nicht skaliert werden. Wie in Entscheidungsbäumen wählt das Modell Punkte im Bereich von Merkmalen aus, an denen Knoten aufgeteilt werden, um Zweige zu bilden, was zu unterschiedlichen Ausgabewerten an den Blättern führt. Die Positionen dieser Teilungen sind unempfindlich gegenüber Merkmalsskalierung.

Um die Genauigkeit des endgültigen Modells zu testen, werden die Eingabedaten zum Zwecke fairer Tests und Modellvalidierung in Trainings- und Testdaten aufgeteilt. Der Testdatensatz stellt eine gesamte durchschnittliche Sonnenzykluslänge dar, von denen keine vom Modell im Trainingsdatensatz gesehen wurde. Indem wir einen ganzen Satz unterschiedlicher Bedingungen des Sonnenzyklus unsichtbar halten und dies zur Validierung verwenden, stellen wir sicher, dass wir die Fähigkeit des Modells bewerten, auf neues Verhalten zu extrapolieren. Der Trainingsdatensatz umfasst 14,5 Jahre, den größten Teil des Sonnenzyklus 23, und läuft von Mai 1992 bis Oktober 2006, während der Testdatensatz die 11 Jahre von Oktober 2006 bis Oktober 2017 abdeckt, was das Ende des Sonnenzyklus 23 und einen großen Teil darstellt vom 24.

Die für diese Studie gewählte Methode des maschinellen Lernens basiert auf GBRs, und die spezifische Implementierung, die hier angewendet wird, ist die Python-Version von XGBoost (Chen & Guestrin, [2016](#)). Der GBR wurde aus einer ersten Studie mit einer Gruppe von Regressoren ausgewählt, darunter auch andere wie Random Forest Regressors. GBRs basieren auf einem Ensemble von Entscheidungsbäumen, die für sich genommen schwache Lerner sind, aber in einem Wald ein mächtiges Vorhersagewerkzeug bilden. Der Begriff Gradient Boosting bezieht sich auf die Gradientenabstiegstechnik, die für eine optimierte Anpassung implementiert wird. Für weitere Details zum Algorithmus siehe Friedman ([2001](#)). Eine Zusammenfassung der allgemeinen Verwendung von GBRs findet sich in Natekin und Knoll ([2013](#)).

Gradientenverstärkende Regressoren und neuronale Netze haben ihre unterschiedlichen Vor- und Nachteile. Im Vergleich zu neuronalen Netzen haben GBRs den Vorteil, dass sie einfacher zu interpretieren sind, da die Mechanismen hinter ihren Vorhersagen (dh Entscheidungsbäumen) gut verstanden sind. Sie haben auch eine einfachere und intuitivere Implementierung und Abstimmung, was zu einer schnelleren Modellentwicklung als bei neuronalen Netzen führt. Auf der anderen Seite ist der Kompromiss für eine einfachere Implementierung, dass sie vorher viel Datenvorbereitung erfordern. Eine der Stärken von Deep Learning neuronalen Netzen ist, dass die Daten oft mit minimalem Handling bereitgestellt werden können, weil das Netz viele Zusammenhänge lernen kann, ohne dass diese explizit vorgegeben sind. Dies ist bei der gradientenverstärkenden Regression nicht so einfach, Daher erläutern wir im Folgenden alle Schritte, die auf die Daten angewendet werden, um sie für das Modelltraining vorzubereiten. Wir wählen ein GBR gegenüber einem komplexeren neuronalen Netzwerk (z. B. rekurrenten oder konvolutionellen neuronalen Netzwerken) für die einfachere Implementierung und Interpretation in Verbindung mit leistungsstarken Lernfähigkeiten und um das Problem der Umgebungssonnenwindvorhersage auf neue Weise anzugehen. Wir vergleichen die Ergebnisse mit der Ausgabe von neuronalen Netzen, die in Yang et al. ([2018](#)) und Chandorkar et al. ([2020](#)) in der Diskussion.


Für den GBR wird für einen bestimmten Satz von Merkmalen ein Hyperparameter-Tuning durchgeführt, bei dem eine Gittersuche verwendet wird, um die beste Kombination von GBR-spezifischen Eingabeparametern zu evaluieren. Dazu wird jeder Punkt im vierdimensionalen Parameterraum innerhalb bestimmter Parameterbereiche untersucht und ein Modell an jedem trainiert. Die Kombination mit der besten Vorhersagefähigkeit gemäß dem gewählten Bewertungsmaß wird für das abschließende Training verwendet. Mit den Ergebnissen der Grid-Suche haben wir ein Modell aus 600 Entscheidungsbäumen gebaut, mehr würde zu Overfitting neigen. Die maximale Tiefe jedes Baums wurde auf 3, die Lernrate auf 0,3 und der L1-Regularisierungsterm auf 20 festgelegt. Eine Sammlung von Verlustfunktionen, die üblicherweise auf Regressionsprobleme angewendet werden, wurde ebenfalls verglichen: der Root-Mean-Square-Error (RMSE), Wurzel Mean Square Log Error (RMSLE), mittlerer absoluter Fehler (MAE) und mittlerer Pseudo-Huber-Fehler (MPHE). Insbesondere die Metriken MAE und MPHE sind nützlich für Trainingsdatensätze mit vielen Ausreißern, die das Training beeinflussen können. Ausreißer waren in unserem Datensatz kein Problem, und der RMSE erwies sich als die robusteste Metrik. In der Praxis hatten Modelle, die entweder mit RMSE, MAE oder MPHE als Verlustmetrik trainiert wurden, eine nahezu gleichwertige Genauigkeit.

Der Trainingsdatensatz wird gemischt und dem Modell mit einer 80/20-Aufteilung zwischen Trainings- und Validierungsdaten bereitgestellt. Durch stratifizierte 5-fache Kreuzvalidierung wird der Validierungsdatensatz beiseite gelegt und während des Trainings verwendet, um die beste Option aus fünf Modellen auszuwählen, und ein frühes Stoppen wird verwendet, um das beste Modell zurückzugeben, bevor eine Überanpassung auftritt.

Merkmalsauswahl

Beim maschinellen Lernen beschreibt die Merkmalsauswahl den Vorgang des Reduzierens oder Anpassens der Eingabemerkmale, um das endgültige Modell zu optimieren und die für das Training benötigte Zeit zu reduzieren. Das Trainieren des Modells mit dem vollständigen Satz von 1.395 Merkmalen mit jeweils etwa 60.000 Datenpunkten ist rechenintensiv, und daher besteht der erste Schritt bei der Merkmalsauswahl darin, einen reduzierten Satz von Variablen zu finden, der ein Modell mit der gleichen Genauigkeit erzeugt. Ein einfacher Ansatz, bei dem die Eingabevariablen im Laufe der Zeit reduziert werden, sodass nur Werte alle -2 , -3 , -4 , -5 und -6 Tage genommen werden, funktioniert genauso gut oder besser als die Merkmalsliste mit allen mögliche Zeitschritte, und die Anzahl der Merkmale sinkt auf 288. Eine detailliertere Merkmalsauswahl erfolgt über verschiedene Methoden, wobei zunächst eine Bewertung der Merkmalswichtigkeit verwendet wird, die das trainierte Modell direkt in Form von Prozentsätzen für jedes einzelne Merkmal bereitstellt, und dann durch Training des Modells auf einzelne Variablen und verschiedene Kombinationen davon. Weitere Einzelheiten zur Wichtigkeit von Merkmalen in GBRs finden sich in Hastie et al. (2009).

Abbildung 2 zeigt eine Bewertung aller Merkmalswichtigkeiten, wobei die Merkmale in Gruppen unterteilt sind. Dies zeigt die Bedeutung jeder der vier Variablen für das Modell, gefolgt von der relativen Bedeutung jeder ADAPT-Modellrealisierung und schließlich der Bedeutung jeder Zeitverschiebung (in Tage gruppiert) für das Modelltraining. Dieses Diagramm folgt weitgehend den erwarteten Mustern: d und f_p sind eindeutig die wichtigsten Eigenschaften, wie von dem WSA-Ansatz erwartet, und unter den Mitgliedern des ADAPT-Ensembles sind einige bemerkenswert besser in der Vorhersage als andere in dieser Kombination. Die anderen beiden Variablen, die sich auf die koronalen und photosphärischen Magnetfelder beziehen, enthalten nicht genügend Informationen, um ein umgebendes Sonnenwindmodell für sich zu tragen, und können ausgeschlossen werden. Unter den zeitverschobenen Variablen liegen die wichtigsten um eine Verschiebung von -4 Tagen, was der durchschnittlichen Zeit entspricht, die der Sonnenwind benötigt, um die Korona zu verlassen, um die Erde zu erreichen, obwohl auch Daten zu anderen Zeitverschiebungen eine Rolle spielen. Diese Merkmalswichtigkeit wurde ohne den Einfluss der statistisch ähnlichen Persistenz der Sonnenwindgeschwindigkeit v_{Pers} bewertet, die neben den anderen trainiert wird, macht fast 20 % der Modellvarianz aus.



Figur 2

[Im Abbildungsbetrachter öffnen](#)[Steckdose](#)

Bedeutung von Features beim Trainieren des Machine-Learning-Modells. Die Merkmalswichtigkeit aller Merkmale gemäß entweder (a) der verwendeten Variablen, (b) der ADAPT-Modellrealisierung, aus der die Variable entnommen wurde, oder (c) der auf die

Variable angewendeten Zeitverschiebung. ADAPT, Air Force Data Assimilative Photospheric Flux Transport.

Das beste Modell, abgeleitet von der Merkmalswichtigkeit, ist eines, das sowohl f_p als auch d mit v_{pers} verwendet, mit Eingaben von drei ADAPT-Modellen (Realisierung Nr. 2, 7 und 8) und die Anzahl der zeitverschobenen Merkmale reduziert auf nur eine pro Tag, insgesamt 33 Funktionen. Dies schneidet besser ab als ein Modell, das auf alle Merkmale trainiert wurde, was eher übertrainiert ist. Insbesondere B_{cor} und B_{phot} schienen sehr situationsspezifisch zu sein, und das Modell schnitt bei neuen Daten ohne sie besser ab. Sobald die beste Auswahl an Merkmalen bestimmt wurde, wird das trainierte Modell als Python-Pickle-Datei für die zukünftige Verwendung gespeichert und für die Validierungsanalyse auf den Testdatensatz angewendet.

Validierungsanalyse

Hier bewerten wir die Entsprechung zwischen den vorhergesagten und beobachteten Zeitreihen der Massengeschwindigkeit des Sonnenwinds auf drei verschiedene Arten. Zunächst stellen wir die Validierungsanalyse in Form einer kontinuierlichen Variablenvalidierung auf der Grundlage einfacher Punkt-zu-Punkt-Vergleichsmetriken vor. Zweitens untersuchen wir die Fähigkeit in Bezug auf binäre Metriken, bei denen wir jeden Zeitschritt in der vorhergesagten und beobachteten Zeitachse als Ereignis/Nicht-Ereignis basierend auf einem ausgewählten Schwellenwert kennzeichnen. Drittens ergänzen wir die diskutierten Validierungstechniken durch einen ereignisbasierten Ansatz, bei dem Perioden mit erhöhter Sonnenwindgeschwindigkeit in Beobachtungen und Vorhersagen automatisch erkannt und miteinander verglichen werden. Diese Validierungsanalyse basiert auf früheren Forschungsarbeiten, wie sie in MJ Owens ([2018](#)) und Reiss et al. ([2020](#)).

2.4.1 Punkt-zu-Punkt-Fehlerfunktionen

Die Vorhersagefähigkeiten von Umgebungssonnenwindmodellen lassen sich am einfachsten beurteilen, indem die beobachteten Sonnenwindzeitreihen mit Umgebungssonnenwindmodelllösungen verglichen werden. Eine einfache Möglichkeit besteht darin, die zugrunde liegenden statistischen Verteilungen in Bezug auf Standardmaße wie Mittelwert, Median und Standardabweichung zu vergleichen. Diese grundlegenden statistischen Maße enthalten bereits wesentliche Informationen über die Tendenz des Modells, die beobachteten Sonnenwindbedingungen zu über- oder unterschätzen. Diese grundlegenden Maßnahmen ergänzen wir mit etablierten Fehlerfunktionen. Wir berechnen verschiedene Fehlerfunktionen für kontinuierliche Variablen wie den mittleren Fehler,

$$ME = \frac{1}{n} \sum_{k=1}^n (f_k - o_k) = \bar{f} - \bar{o}, \quad (3)$$

wobei (f_k, o_k) das k -te Element von insgesamt n Vorhersage- und Beobachtungspaaren ist. Hier ist die ME einfach die Differenz zwischen der durchschnittlichen Vorhersage und der durchschnittlichen Beobachtung. Außerdem berechnen wir den mittleren absoluten Fehler,

$$MAE = \frac{1}{n} \sum_{k=1}^n |f_k - o_k|. \quad (4)$$

Der MAE ist das arithmetische Mittel der absoluten Differenzen zwischen den Vorhersage- und den Beobachtungspaaren. Er stellt die typische Größe für den Vorhersagefehler dar. Ähnlich wie beim MAE, dem Root-Mean-Square-Error,

$$RMSE = \sqrt{\frac{1}{n} \sum_{k=1}^n (f_k - o_k)^2}, \quad (5)$$

ist die mittlere quadratische Differenz zwischen Vorhersage- und Beobachtungswertpaaren. Der RMSE ist eine Schätzung des Ausmaßes des Prognosefehlers, der empfindlicher auf Ausreißer reagiert als der MAE. Das letzte Fehlermaß ist der Skill-Score:

$$SS = 1 - \frac{MSE_{\text{pred}}}{MSE_{\text{ref}}}, \quad (6)$$

der die mittleren quadratischen Fehler (MSE) zwischen der Vorhersage und der Referenz vergleicht. Diese Maße sind gleich Null für den Fall, dass die Vorhersagefehler gleich Null sind (also $f_k = o_k$) und steigen mit zunehmender Abweichung zwischen Vorhersagen und Beobachtungen. Obwohl streng genommen keine Fehlerfunktion per Definition, ergänzen wir die Fehlerfunktionen mit dem Pearson-Korrelationskoeffizienten.

2.4.2 Binäre Metriken

Neben Ansätzen, die die Größe des Vorhersagefehlers in jedem Zeitschritt im Vergleich zum beobachteten Wert bewerten, verwenden wir einen anderen Ansatz, bei dem jeder Zeitschritt in der Sonnenwind-Zeitreihe in binären Werten als Ereignis oder Nicht-Ereignis gekennzeichnet wird. Ein Schwellenwert wird ausgewählt, und alle Werte über dem Schwellenwert werden als Ereignisse definiert, während die Werte darunter Nicht-Ereignisse sind. Der Vorteil dieser Methode besteht darin, dass langsamer und schneller Sonnenwind, von denen der schnelle Sonnenwind für Endverbraucher von größerem Interesse ist, nicht die gleiche Bedeutung erhalten (MJ Owens, 2018 [1](#)). Es ist auch im Allgemeinen unempfindlich gegenüber Ausreißern, die für eine Prognose irrelevant sind, aber Punkt-zu-Punkt-Fehlermaße stark beeinflussen können.

Die Definition von Ereignissen und Nichtereignissen in der Sonnenwindzeitreihe verwendet einen ausgewählten Schwellenwert (Reiss et al., [2020](#)) von 450 km/s. Wir vergleichen Ereignisse und Nicht-Ereignisse in den vorhergesagten und beobachteten Sonnenwind-Zeitreihen und zählen die Anzahl der Treffer (true positives; TPs), Fehlalarme (false positives; FPs), Misses (false negatives; FNs) und korrekter Zurückweisungen (true negatives; TNs), die in einer Kontingenztabelle aufgeführt sind. Ein Treffer ist ein korrekt vorhergesagtes Ereignis, während ein Fehlschlag ein Ereignis ist, das beobachtet, aber nicht vorhergesagt wird. Im Gegensatz dazu ist ein falscher Alarm ein vorhergesagtes Ereignis, das nicht beobachtet wurde, und eine korrekte Zurückweisung ist ein korrekt vorhergesagtes Nicht-Ereignis. Die Gesamtzahlen werden in der sogenannten Kontingenztabelle zusammengefasst, und daraus berechnen wir eine Reihe von Fähigkeitsmaßen, wie die True-Positive-Rate $TPR = TP/(TP + FN)$, die Falsch-Positiv-Rate $FPR = FP/(FP + TN)$, Threat Score $TS = TP/(TP + FP + FN)$, Bias $BS = (TP + FP)/(TP + FN)$ und True Skill Statistics $TSS = TPR - FPR$. Der Bedrohungswert ist ein Maß für die Gesamtleistung eines Modells, das zwischen 0 und 1 (beste Leistung) definiert ist, während die Verzerrung darstellt, wie stark das Modell dazu neigt, Ereignisse zu überschätzen ($BS > 0$) oder zu unterschätzen ($BS < 0$). Ein aussagekräftiges Skill-Maß ist die True Skill Statistics (TSS), die im Bereich $[-1, 1]$ definiert ist. Ein perfektes Vorhersagemodell hätte einen Wert von 1 (oder -1 für perfekt inverse Vorhersagen), und ein TSS von 0 zeigt keine Fähigkeit an. Der Vorteil der TSS besteht darin, dass sie alle Elemente der Kontingenztabelle kombiniert und unabhängig vom Anteil vorhergesagter und beobachteter Ereignisse ist (Bloomfield et al., 0) oder Untervorhersage ($BS < 0$) von Ereignissen. Ein aussagekräftiges Skill-Maß ist die True Skill Statistics (TSS), die im Bereich $[-1, 1]$ definiert ist. Ein perfektes Vorhersagemodell hätte einen Wert von 1 (oder -1 für perfekt inverse Vorhersagen), und ein TSS von 0 zeigt keine Fähigkeit an. Der Vorteil der TSS besteht darin, dass sie alle Elemente der Kontingenztabelle kombiniert und unabhängig vom Anteil vorhergesagter und beobachteter Ereignisse ist

(Bloomfield et al., 0) oder Untervorhersage ($BS < 0$) von Ereignissen. Ein aussagekräftiges Skill-Maß ist die True Skill Statistics (TSS), die im Bereich $[-1, 1]$ definiert ist. Ein perfektes Vorhersagemodell hätte einen Wert von 1 (oder -1 für perfekt inverse Vorhersagen), und ein TSS von 0 zeigt keine Fähigkeit an. Der Vorteil der TSS besteht darin, dass sie alle Elemente der Kontingenztafel kombiniert und unabhängig vom Anteil vorhergesagter und beobachteter Ereignisse ist (Bloomfield et al., [2012](#); Hanssen & Kuipers, [1965](#); Wilke, [2011](#)).

Die Receiver Operator Characteristic (ROC)-Kurve fasst die Vorhersagefähigkeiten für eine Reihe unterschiedlicher Ereignisschwellenwerte übersichtlich zusammen. Die Kurven veranschaulichen, wie die Anzahl korrekt vorhergesagter Ereignisse (TPR) mit der Anzahl falsch vorhergesagter Nicht-Ereignisse (FPR) variiert.


2.4.3 Ereignisbasierte Validierung

Die oben beschriebene Interpretation einfacher Punkt-zu-Punkt-Vergleiche kann aufgrund fehlender Kenntnisse über das Ausmaß der Unsicherheiten im Zusammenhang mit Zeitfehlern irreführend sein (MacNeice, 2009a, 2009b; Owens et al., [2005](#)). Dies ist insbesondere dann der Fall, wenn große Schwankungen in den Sonnenwindzeitreihen im Allgemeinen gut vorhergesagt werden, die Ankunftszeiten jedoch zwischen Vorhersage und Beobachtungen unterschiedlich sind. Die Verwendung einer ereignisbasierten Validierungstechnik wird üblicherweise angewendet, um die Unsicherheiten in den Ankunftszeiten zu berücksichtigen. Genauer gesagt wird die Validierungsanalyse am Beispiel der Massengeschwindigkeit des Sonnenwinds in drei Schritten durchgeführt. Erstens werden Ereignisse mit erhöhter Sonnenwindgeschwindigkeit, die in Vorhersage- und Beobachtungsdaten auch als High-Speed Enhancements (HSEs) bezeichnet werden, als Perioden definiert, die einen bestimmten Schwellenwert überschreiten. Als nächstes werden HSEs, die in den Sonnenwindmessungen erkannt wurden, mit HSEs in den Vorhersagen gepaart, und jedes Ereignispaar wird als Treffer, Fehlalarm oder Fehlschlag gekennzeichnet. Die Vorhersagefähigkeiten des Modells werden unter Verwendung der Validierungszusammenfassungsveränderlichen bestimmt. Eine ausführlichere Beschreibung der oben diskutierten Schritte, angewandt auf Messungen der Sonnenwindgeschwindigkeit, findet sich in Reiss et al. ([2016](#)) in Abschnitt 3.2.

3. Ergebnisse

Eine Validierung der Ergebnisse für einen Sonnenzyklus aus dem maschinellen Lernmodell mit gängigen Metriken wie Punkt-zu-Punkt-Maßnahmen zeigt, dass die GBR die WSA/HUX-Modellkombination und die 27-Tage-Persistenz in fast allen Maßnahmen übertrifft. Die Ergebnisse des Modells sind neben der Beispieleingabe in Abbildung [3](#) für fünf Carrington-Rotationen im Sonnenzyklus 24 dargestellt, an dem das Modell getestet wurde. Die beobachtete Entwicklung des Sonnenwinds ist im unteren Bild in Schwarz aufgetragen (mit der vom WSA/HUX-Modell ermittelten Sonnenwindgeschwindigkeit zum Vergleich in Orange), und wir sehen eine gute Übereinstimmung. Das auf den gesamten Testdatensatz angewendete Modell ist in Abbildung [4](#) dargestellt. Aus einer anderen Perspektive, Bild [5](#) zeigt die Ausgabe des Modells über den gesamten zeitlichen Bereich der Testdaten als Entwicklung über alle 146 Carrington-Rotationen. Die gute visuelle Übereinstimmung zwischen den Beobachtungen (links) und Vorhersagen (rechts) zeigt, dass das Modell die umgebenden Sonnenwindströmungen gut approximiert. Kürzere, transiente Sonnenwindströmungen, die hauptsächlich um das Sonnenmaximum herum zu sehen sind


(Bildmitte), erscheinen nicht in den Modellvorhersagen, aber dies ist wie erwartet, da das Modell nur den sich entwickelnden umgebenden Sonnenwind vorhersagt.



Figur 3

[Im Abbildungsbetrachter öffnen](#)[Steckdose](#)

Input (a)–(b) und Output (c) aus dem umgebenden Sonnenwindmodell. Variation des Flussröhren-Ausdehnungsfaktors f_p (a) und des Abstands zur koronalen Lochgrenze d (b) über fünf Carrington-Rotationen (CR 2182–2187) bei einer Zeitverschiebung von $t - 4$ Tagen relativ zum Zeitschritt der letzten Sonne Vorhersage der Windgeschwindigkeit. Die Ausgabe aller 12 ADAPT-Realisierungen wird in Farbe angezeigt, während die schwarze Linie den Mittelwert darstellt. (c) Sonnenwindgeschwindigkeit, vorhergesagt aus dem maschinellen Lernmodell (blaugrün) und dem WSA/HUX-Modell (orange), aufgetragen gegen die beobachtete Sonnenwindgeschwindigkeit (schwarz). Vorhersagen erfolgen während des Sonnenminimums im Sonnenzyklus 24, an dem das Modell getestet wurde. ADAPT, Air Force Data Assimilative Photospheric Flux Transport.



Figur 4

[Im Abbildungsbetrachter öffnen](#)[Steckdose](#)

Von oben nach unten: aufeinanderfolgende Jahre von Sonnenwindbeobachtungen auf der Erde (schwarze Linie), aufgetragen neben Vorhersagen des maschinellen Lernmodells (blaugrün). Der RMSE für jedes Jahr wird rechts hinzugefügt. Alle y-Achsen sind auf den Bereich 200–800 km/s skaliert. RMSE, Root-Mean-Square-Error.

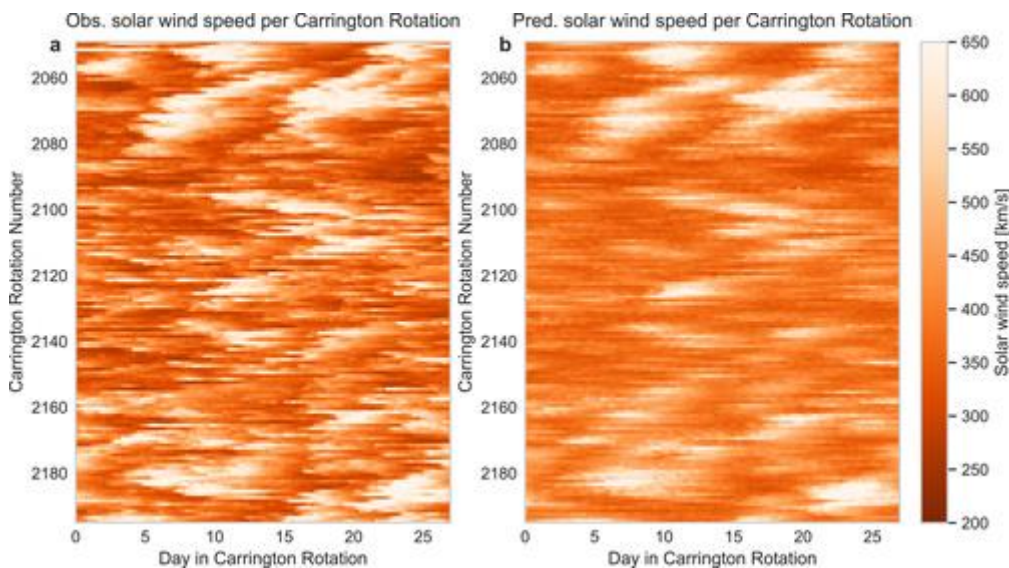


Abbildung 5

[Im Abbildungsbetrachter öffnen](#)[Steckdose](#)

Die Entwicklung der Sonnenwindgeschwindigkeit in Beobachtungen und Vorhersagen über die Zeit. (a) und (b) zeigen die Änderung der Sonnenwindgeschwindigkeit pro Carrington-Rotation (27 Tage) für den gesamten Testdatensatz, 11 Jahre oder 146 Carrington-Rotationen. Die Zeit nimmt von oben nach unten zu, und jede Zeile des Bildes ist eine Carrington-Drehung. (a) Zeigt die Sonnenwindgeschwindigkeit in den Beobachtungen bei L1, während (b) die vorhergesagte Sonnenwindgeschwindigkeit aus dem maschinellen Lernmodell zeigt. Wie zu sehen ist, stimmen wiederkehrende Muster gut zwischen Beobachtungen und Vorhersagen überein, obwohl Kurzzeitsignale, wie sie meistens um das Sonnenmaximum herum (Bildmitte) zu sehen sind, vom Modell nicht reproduziert werden.

Die Tabellen 1–3 fassen die Ergebnisse der Modellvalidierung in Bezug auf Punkt-zu-Punkt-Messungen, Fertigmessungen bzw. ereignisbasierte Metriken zusammen. Es werden mehrere maschinelle Lernmodelle mit unterschiedlichen Eingabevariablen betrachtet, und die Eingabevariablen sind in Klammern aufgeführt. Neben dem Flussröhren-Ausdehnungsfaktor f_p und dem Abstand zur koronalen Lochgrenze d wurde auch die Sonnenwindgeschwindigkeit von vor 27 Tagen (v_{pers}) aufgenommen. Wir finden, dass die besten Ergebnisse in Bezug auf etablierte Fehlerfunktionen mit dem GBR-Modell basierend auf f_p , d und v_{pers} mit einem RMSE von $78,3 \text{ km s}^{-1}$ erhalten werden und einen PCC von 0,63. (Als Referenz, die RMSE- und PCC-Werte auf den Trainings-/Validierungssätzen für dieses Modell waren $96,1/99,1 \text{ km/s}$ bzw. $0,66/0,64$. Der höhere RMSE ist eine Folge davon, dass SC 23 viel aktiver ist, und ebenso höher Wert ist im WSA-Modell zu sehen.) Im Vergleich dazu beträgt der RMSE für die herkömmliche WSA/HUX-Modellkombination $98,9 \text{ km s}^{-1}$ und der PCC 0,49. Die Ergebnisse für das Modell der 27-Tage-Persistenz mit einem RMSE von $98,2 \text{ km s}^{-1}$ und ein PCC von 0,52 zeigen an, dass es eine starke Benchmark darstellt. Das Persistenzmodell profitiert stark davon, dass es die gleichen Statistiken wie die Beobachtungen hat, wie durch die ähnlichen AM und SD angezeigt wird, und die sich wiederholende Natur des umgebenden Sonnenwindflusses. Wir stellen auch fest, dass alle in dieser Studie untersuchten maschinellen Lernansätze die Ergebnisse im Vergleich zum klimatologischen Mittel verbessern, was durch einen SS von 0,02 und einen SS von mehr als 0,15 für alle GBRs angezeigt wird.

Tabelle 1. Klassische Punkt-zu-Punkt-Fehlermaße für den Modellvergleich

Modell	AM [km s^{-1}]	SD [km s^{-1}]	ME [km s^{-1}]	MAE [km s^{-1}]	RMSE [km s^{-1}]	SS	PCC
WSA/HUX	386.1	80.5	34.9	72.3	98.9	0,02	0,49
GBR(d)	430.7	57.4	−9.7	70.6	89.4	0,20	0,47
GBR(f_p)	429.1	49.6	−8.1	72.6	91.3	0,16	0,42
GBR(f_p , d)	427.7	61.6	−6.7	66.8	85,0	0,28	0,54
GBR(f_p , d , v_{pers})	422.3	71.6	−1.3	59.9	78.3	0,39	0,63
Persistenz (27 Tage)	420.8	99,8	0,1	71.9	98.2	0,03	0,52

Modell	AM [km s ⁻¹]	SD [km s ⁻¹]	ME [km s ⁻¹]	MAE [km s ⁻¹]	RMSE [km s ⁻¹]	SS	PCC
Überwachung	421.0	99,9	–	–	–	–	–

- Tabelle der Fehlermetriken für die Vorhersage des Umgebungssonnenwinds in Bezug auf das arithmetische Mittel (AM), die Standardabweichung (SD), den mittleren Fehler (ME), den mittleren absoluten Fehler (MAE), den mittleren quadratischen Fehler (RMSE), den Skill-Score (SS) relativ zum klimatologischen Mittel und dem Pearson-Korrelationskoeffizienten (PCC).

In Bezug auf die Kontingenztabelle in Tabelle 2 stellen wir fest, dass die Anwendung des besten maschinellen Lernansatzes alle Fähigkeitsmessungen verbessert, und insbesondere, dass die GBRs, die auf verschiedenen Merkmalskombinationen basieren, die Anzahl der Treffer verbessern und die Anzahl der Fehlschläge verringern. Während die TP-Anzahl in $GBR(d)$ im Vergleich zum WSA/HUX-Modell ziemlich hoch ist, ist die FP-Anzahl ebenfalls hoch. $GBR(f_p)$ hingegen erscheint in Vorhersagen mit niedrigerem TP und FP und mit einer größeren Anzahl von FN konservativer. Die Kombination der beiden in $GBR(f_p, d)$ führt zu Verbesserungen in allen Maßnahmen, und das Hinzufügen der v_{pers} führt zu weiteren Verbesserungen. Im Vergleich zu WSA/HUX erhöhen die Techniken des maschinellen Lernens die Anzahl der Fehlalarme und verringern die Anzahl der korrekten Zurückweisungen. Der TSS ist bei allen Machine-Learning-Ansätzen größer als der Wert 0,28 (WSA/HUX-Modell). Dieser positive Anstieg des TSS weist darauf hin, dass die Gesamtleistung der maschinellen Lerntechniken einen positiven Trend zu korrekt vorhergesagten verbesserten Sonnenwindbedingungen zeigt. Während die traditionelle WSA/HUX-Modellkombination dazu neigt, die Anzahl der Perioden erhöhter Sonnenwindgeschwindigkeiten ($BS = 0,57$) zu unterschätzen, ähneln die maschinellen Lernansätze viel besser der Anzahl der Ereignisse in den Sonnenwindbeobachtungen.

Tabelle 2. Kontingenztabelle mit Fähigkeitsmessungen von Sonnenwindgeschwindigkeitsereignissen

Modell	TP	FP	FN	TN	TPR	FPR	TS	TSS	BS
WSA/HUX	3.106	1.711	5.306	16.410	0,37	0,09	0,31	0,28	0,57
$GBR(d)$	4.440	3.722	3.972	14.399	0,53	0,21	0,37	0,32	0,97
$GBR(f_p)$	3.800	3.118	4.612	15.003	0,45	0,17	0,33	0,28	0,82
$GBR(f_p, d)$	4.377	2.969	4.035	15.152	0,52	0,16	0,38	0,36	0,87
$GBR(f_p, d, v_{pers})$	4.714	2.368	3.698	15.753	0,56	0,13	0,44	0,43	0,84
Persistenz (27 Tage)	4.873	3.464	3.472	14.546	0,58	0,19	0,41	0,39	1.00

- Die Ereignisschwelle wird auf $v > 450 \text{ km s}^{-1}$ festgelegt. Die Tabelle zeigt die Anzahl der Treffer (True Positives; TPs), Fehlalarme (False Positives; FPs), Misses (False Negatives,

FNs), korrekte Zurückweisungen (True Negatives, TNs), gefolgt von Metriken, die von diesen Werten abgeleitet wurden: das Wahre Positivrate (TPR) und Falsch-Positiv-Rate (FPR). Die letzten drei Einträge in jeder Zeile zeigen den Bedrohungswert (TS), die wahren Fähigkeitenstatistiken (TSS) und die Voreingenommenheit (BS). GBR, Gradient Boosting Regressor.

Abbildung 6 zeigt die berechneten ROC-Kurven für alle untersuchten Ansätze zur Sonnenwindmodellierung. *Wir stellen fest, dass die auf f_p , d und v_{pers} basierende GBR die WSA/HUX-Modellkombination für das gesamte Spektrum ausgewählter Ereignisschwellenwerte und die Persistenz bei fast allen Schwellenwerten übertrifft.*




Abbildung 6

[Im Abbildungsbetrachter öffnen](#)[Steckdose](#)

Empfänger-Operator-Charakteristikkurven, die die True-Positive-Rate (TPR) gegenüber der False-Positive-Rate (FPR) für die untersuchten maschinellen Lerntechniken und die Referenzmodelle zeigen. Die AUC (Fläche unter der Kurve) ist in der Legende enthalten. Je näher dieser Wert an 1,0 liegt, desto besser ist die Leistung des Modells.

Die letzte Bewertung war eine ereignisbasierte Analyse, die in Tabelle 3 gezeigt wird. Wir stellen fest, dass das maschinelle Lernmodell die Ergebnisse der WSA/HUX-Modellkombination leicht verbessert. Wir stellen auch fest, dass die Anzahl der korrekt vorhergesagten Ereignisse für alle maschinellen Lerntechniken zunimmt und die Anzahl der Fehlschläge abnimmt. Allerdings steigt die Zahl der Fehlalarme für die Techniken des maschinellen Lernens. Während der TS für das WSA/HUX-Modell 0,33 beträgt, basiert der

TS für das GBR auf f_p , d und v_{pers} ist 0,40. Dies weist darauf hin, dass die meisten maschinellen Lernansätze eine angemessene Verbesserung im Vergleich zum traditionellen Ansatz bieten. Das Modell der Persistenz bietet jedoch wiederum einen herausfordernden Vergleich im Sinne einer ereignisbasierten Validierungsanalyse.

Tabelle 3. Statistiken zu ereignisbasierten Fehlermetriken

Modell	P	P_F	BS	TP	FP	FN	POD	FNR	PPV	Weit	TS
WSA/HUX	451	223	0,49	167	56	284	0,37	0,63	0,75	0,25	0,33
GBR(d)	451	305	0,68	201	104	250	0,45	0,55	0,66	0,34	0,36
GBR(f_p)	451	279	0,62	179	100	272	0,40	0,60	0,64	0,36	0,33
GBR(f_p, d)	451	307	0,68	211	96	240	0,47	0,53	0,69	0,31	0,39
GBR(f_p, d, v_{pers})	451	292	0,65	213	79	235	0,48	0,52	0,73	0,27	0,40
Persistenz (27 Tage)	451	449	1.00	287	162	161	0,64	0,36	0,64	0,36	0,47

- Eine Bewertung der Erkennungen von Hochgeschwindigkeitsverbesserungen wurde in Bezug auf ereignisbasierte Metriken durchgeführt, einschließlich der Anzahl der beobachteten (P) und vorhergesagten (P_F) Ereignisse, des Bias (BS), der Anzahl der Treffer (TPs), falsch Alarme (FPs) und Misses (FNs) zusammen mit der Erkennungswahrscheinlichkeit (POD), der Falsch-Negativ-Rate (FNR), dem positiven Vorhersagewert (PPV), dem Falschalarmverhältnis (FAR) und dem Bedrohungswert (TS). GBR, Gradient Boosting Regressor.

4. Diskussion

Modellüberlegungen

Bei der Bewertung dieser Arbeit sind einige Aspekte zu berücksichtigen. Erstens berücksichtigt der aktuelle Modellierungsansatz keine Effekte aus der komplexen dynamischen Entwicklung des umgebenden Sonnenwindflusses und berücksichtigt daher keine Wechselwirkungen zwischen schnellem und langsamem umgebendem Sonnenwind. Daher liefert es kein Bild der Sonnenwindbedingungen in der Heliosphäre und bietet keinen selbstkonsistenten Weg, um die Lösungen von der Sonne zur Erde zu verbreiten. Um der Unsicherheit in den Zeitreihen Rechnung zu tragen, verwenden wir Funktionen, die auf Zeitverschiebungen mit einer Kadenz von 3,64 h im Bereich von 2 bis 6 Tagen basieren. Während des Prozesses der Identifizierung der wichtigsten Merkmale stellen wir fest, dass diejenigen zwischen 3 und 4 Tagen am kritischsten sind, wie es von der typischen Transitzeit von umgebenden Sonnenwindströmungen zu erwarten wäre.

Zweitens enthält das Modell ähnliche Quellen von Ungenauigkeiten wie andere Modelle, die auf photosphärischen Magnetfeldmessungen basieren, wie z. B. das WSA-Modell, und Fehler im koronalen Magnetmodell werden sich auf die Vorhersagen bei L1 erstrecken. Eine Fehlerquelle liegt zB in der magnetischen Konnektivität, wenn die Feldlinienverfolgung einen

falschen Quellort des Sonnenwindes offenbart. Dies kann aus Unsicherheiten in den Magnetogrammen oder dem Auftauchen aktiver Regionen auf der anderen Seite der Sonne resultieren, die das globale Feld verzerren. Fehlerquellen wie diese im koronalen Bereich erklären vom Modell übersehene Verbesserungen der Sonnenwindgeschwindigkeit, wie zum Beispiel Anfang 2017 in Abbildung 3. Ganz allgemein gibt es auch die anhaltende Diskussion über die Position der Quellenoberflächenhöhe, die oft eine bessere Modellgenauigkeit bietet, wenn sie über den Zyklus variiert, wie speziell für die Sonnenzyklen 23 und 24 in Lee et al. (2011) und Arden et al. (2014).

Drittens stellen wir fest, dass die Ergebnisse in der vorliegenden Studie aus einer operativen Perspektive abgeleitet wurden. Dies bedeutet, dass magnetische Merkmale einmal pro Tag berechnet wurden. Da der größte Teil der veröffentlichten Literatur die magnetischen Merkmale nur einmal pro Carrington-Rotation berechnet, haben wir diese Einstellung auch für alle untersuchten Modelle des maschinellen Lernens getestet. Wir stellen fest, dass die Modellqualität in Bezug auf den RMSE des GBR mit dieser neuen Einstellung um etwa 5 Prozent abnimmt. Die Kenntnis dieser Variation ist wichtig, um unsere Ergebnisse mit bestehenden Studien in Zusammenhang zu bringen. Wir stellen fest, dass das endgültige Modell, auf das online auf GitHub zugegriffen werden kann, daher auch direkt auf operationelle numerische Rahmenwerke zur Vorhersage des Umgebungssonnenwinds angewendet werden kann.

Hervorzuheben ist, dass wir in Bezug auf Sonnenzyklen zwischen Trainings-, Validierungs- und Testdatensätzen unterschieden haben. Wir haben einen Zeitraum verwendet, der die zweite Hälfte des Sonnenzyklus 22 und den größten Teil des Sonnenzyklus 23 für das Training und die laufende Validierung abdeckt, um die besten Parameter und Merkmale für die spezifische maschinelle Lerntechnik abzuleiten. Wir präsentierten unsere Validierungsanalyseergebnisse für den Testdatensatz, der einen Zeitraum von einer durchschnittlichen Sonnenzykluslänge (11 Jahre) abdeckte, der vom Ende des Sonnenzyklus 23 bis einschließlich des größten Teils des Sonnenzyklus 24 reichte. Keine der angegebenen Fehlerschätzungen bezieht sich auf die Ausgabe des Modells auf den Daten, auf denen es trainiert wurde, da dies keine genaue Schätzung der Vorhersagefähigkeit des Modells liefern würde, wenn es mit neuen Daten versorgt wird. Die Ergebnisse sind daher eine vernünftige Schätzung der realen Leistung des dargestellten Regressors. In diesem Zusammenhang haben wir auch versucht, die Rollen von Sonnenzyklus 23 und 24 auszutauschen, und festgestellt, dass die Ergebnisse für ein Modell, das mit Sonnenzyklus 24 trainiert und mit Sonnenzyklus 23 getestet wurde, vergleichbar sind, ohne große Abweichungen in den Fehlermetriken. Beispielsweise beträgt der RMSE für die Tests im Sonnenzyklus 23 92,1 km/s. Solarzyklus 23 war deutlich aktiver als Zyklus 24, daher ist ein höherer RMSE zu erwarten. Dies unterstreicht, dass der abgeleitete Regressor nicht nur schnell, sondern auch robust ist. Beispielsweise beträgt der RMSE für die Tests im Sonnenzyklus 23 92,1 km/s. Solarzyklus 23 war deutlich aktiver als Zyklus 24, daher ist ein höherer RMSE zu erwarten. Dies unterstreicht, dass der abgeleitete Regressor nicht nur schnell, sondern auch robust ist. Beispielsweise beträgt der RMSE für die Tests im Sonnenzyklus 23 92,1 km/s. Solarzyklus 23 war deutlich aktiver als Zyklus 24, daher ist ein höherer RMSE zu erwarten. Dies unterstreicht, dass der abgeleitete Regressor nicht nur schnell, sondern auch robust ist.

Der hier vorgestellte Machine-Learning-Ansatz könnte die Ergebnisse der etablierten Modelle wie WSA verbessern, sollte aber nicht als Ersatz für diesen Modellierungsansatz angesehen werden. Zum Beispiel enthalten Modellkombinationen auf der Grundlage von MHD von Natur aus wichtige Informationen über den Ort, die Grenzen und die Dynamik offener Magnetfeldlinien, entlang derer sich Hochgeschwindigkeits-Sonnenwindströme in den

interplanetaren Raum beschleunigen. Solche Informationen sind unerlässlich, da sie letztendlich unser Verständnis der zugrunde liegenden physikalischen Prozesse verbessern.

Der maschinelle Lernansatz wird der Weltraumwettergemeinschaft über das Ambient Solar Wind Validation Team zur Verfügung gestellt, das in die COSPAR/ISWAT-Initiative eingebettet ist (<https://iswat-cospar.org/H1-01>). Die Rechenzeit des endgültigen maschinellen Lernprodukts ist sehr schnell und erfordert etwa 100 μ s (auf einem Macbook Pro 13" A1708), um eine Reihe von 4-Tages-Vorhersagen aus Daten bereitzustellen, die aus solarmagnetischen Karten extrahiert wurden. Diese Geschwindigkeit macht Ensemble-Läufe möglich, wobei 1 Million Läufe 100 s benötigen, in einer optimierten Umgebung auf einem dedizierten Server mit Multiprocessing wären es nur eine Frage von Sekunden. Eine mögliche Anwendung könnte Unsicherheiten in den koronalen Feldlösungen in den Vorhersagen der Sonnenwindgeschwindigkeit enthalten, indem Ensembles aller magnetischen Modellmerkmale innerhalb von $\pm 3^\circ$ der Bahn unter der Erde ausgeführt werden. In Zukunft werden wir an mehreren Themen arbeiten, die mit der Verbesserung des Ansatzes und seiner Erweiterung auf andere physikalische Eigenschaften wie magnetische Polarität und Grenzübergänge von magnetischen Sektoren zusammenhängen. Darüber hinaus planen wir, die globalen Sonnenwindlösungen in der Nähe der Sonne auf der Grundlage einer ähnlichen Methodik zu berechnen.

Auswerten, was nicht funktioniert hat

Ein Vorteil von maschinellen Lernalgorithmen, besonders effizienten Methoden wie Gradient Boosting Regressors, ist die Möglichkeit, viele verschiedene Eingabevariablen zu prüfen und zu optimieren, anstatt sich mit einigen wenigen zufrieden zu geben. In dieser Arbeit haben wir Modelle vorgestellt, die auf drei Variablen (f_p , d und v_{pers}) trainiert wurden, aber weitaus mehr Variablen wurden ausprobiert, bevor sie ausgeschlossen wurden, und die Diskussion darüber, welche funktionierten und welche nicht, ist an sich schon interessant.

Zunächst haben wir Merkmale in Bezug auf die Sonnenaktivität aufgenommen, wobei die F10.7- oder MgII-Indizes weit verbreitete Beispiele dafür sind. Wir erwarteten, dass sich die Vorhersagen verbessern würden, wenn Informationen über das Aktivitätsniveau auf der Sonne bereitgestellt würden. Überraschenderweise wurde festgestellt, dass Modelle, die mit einem oder beiden trainiert wurden, bei neuen Daten nicht besser abschneiden. Dies impliziert, dass über die verwendeten Variablen bereits ausreichend Informationen über den Zustand des Sonnenwindes geliefert wurden. In den Fällen von F10.7 wurden die Modelle auch leichter übertrainiert, was impliziert, dass dieser Index nicht gut verallgemeinert werden kann. Dies verleiht unserem Modell weiteres Vertrauen in die Fähigkeit, Informationen über magnetische Aktivität und offene Feldzykluskomponenten aus den bereitgestellten Funktionen korrekt zu extrahieren, ohne lediglich bestimmte Konfigurationen zu lernen.

Zweitens untersuchten wir, ob die Einbeziehung von Details zu den koronalen Löchern, wie sie von den koronalen Modellen definiert wurden, zu einer Verbesserung der Modellgenauigkeit führen könnte. Details wie die Fläche der koronalen Löcher über alle Breiten/niedrigen Breiten/hohen Breiten (aufgenommen über erdzugewandte Schnitte wie bei den anderen Variablen), die durchschnittliche Länge der koronalen Löcher und das Gesamtfeld in den koronalen Löchern wurden eingeschlossen. Die einzige Variable, die zur Modellgenauigkeit beitrug, war der Bereich der koronalen Löcher in niedrigen Breiten, während die anderen vernachlässigbar waren. Ein auf f_p und d trainiertes Modell Mit diesem koronalen Lochmerkmal wurde zusätzlich eine Genauigkeitssteigerung von einigen Prozent erzielt. Dies steht im Einklang mit der aktuellen Literatur und den Ergebnissen empirischer Vorhersagemodelle auf der Grundlage von EUV-Informationen, die am besten funktionieren,

wenn dominante koronale Löcher in niedrigen Breiten beobachtbar sind, aber ihnen fehlt es an Genauigkeit in Bezug auf die zeitliche Entwicklung des Sonnenwinds (Reiss et al., [2016](#)). Während das koronale Lochmerkmal die Genauigkeit eines Modells mit f_p und d verbesserte, gab es keine Erhöhung, wenn v_{pers} einbezogen wurde, und um die Analyse kurz zu halten, beschränkten wir uns auf Modelle, die auf f_p und d trainiert wurden.

Interessant ist in diesem Zusammenhang auch eine Untersuchung zur Verwendung von ADAPT-Realisierungen. Ein Modell, das mit allen 12 ADAPT-Realisierungen trainiert wurde, war leichter übertrainiert, aber ein Modell, das mit nur einer Realisierung trainiert wurde, schnitt nicht so gut in der Genauigkeit ab. Unsere Analyse zeigte, dass sich die Verwendung von drei Realisierungen als ein gutes Gleichgewicht herausstellte, wobei verschiedene Kombinationen zu Modellen mit ähnlichen Genauigkeitsniveaus führten, wobei die in den Ergebnissen beschriebene Kombination am stabilsten war. Das ADAPT-Ensemble repräsentiert die Unsicherheit der Flussposition an den Polen und auf der anderen Seite als Ergebnis des zufälligen Flusslaufs, der durch Supergranulations-Strömungsmuster angetrieben wird. Wenn das Ensemble groß genug ist, um die Hauptunsicherheitsquellen zu berücksichtigen, wird der „echte Sonnenwind“ innerhalb des Lösungsensembles liegen.

Interpretierbarkeit von Machine-Learning-Modellen

Machine-Learning-Modelle, insbesondere Deep-Learning-Modelle, leiden oft unter der Kritik, schwer interpretierbar zu sein. Das Gradient-Boosting-Regressionsmodell ist einigermaßen interpretierbar. Ein einfacher zu bewertender Teil ist die Wichtigkeit jedes Eingabemerkmals, das durch den Anteil der Verzweigungspunkte bestimmt wird, aus denen sie bestehen, was die Vorhersagekraft jeder Variablen darstellt.

Während unserer Analyse haben wir die Rollen von f_p und d bewertet, die mit verschiedenen Theorien über den Ursprung des langsamen Sonnenwinds verbunden sind. Während die Idee von f_p mehr mit Wellen und Turbulenzen zusammenhängt, impliziert d , dass die Wiederverbindung des Austauschs an der Grenze des koronalen Lochs den Ursprung des langsamen Sonnenwinds bestimmt (Riley et al., [2015](#)). In diesem Zusammenhang haben wir die Änderung der Merkmalsbedeutung jeder Variablen im Laufe der Zeit untersucht. Dazu haben wir Modelle über kürzere Zeiträume (1–3 Jahre) trainiert und bewertet, wie sich die Wichtigkeit der Merkmale über den Sonnenzyklus verändert. Ein Dualitätsmuster zwischen f_p und d entsteht. Wir fanden heraus, dass sie sich während der Sonnenzyklen abwechselten, wobei d während der ansteigenden Phase des Sonnenzyklus und f_p während der abnehmenden Phase bessere Vorhersagen lieferte. Diese Feature-Wichtigkeitsanalyse im Bereich des maschinellen Lernens bietet eine interessante Perspektive auf dieses anstehende Problem, aber wir können keine endgültige Aussage darüber treffen, welche der Variablen wichtiger ist.

Vergleich mit ähnlichen Studien

Wir stellen fest, dass ein ähnlicher Ansatz bereits in der wissenschaftlichen Literatur existiert, der von Yang et al. ([2018](#)). Die Studie wurde wie folgt durchgeführt: Etwa 9 Jahre Daten wurden zufällig in Trainings-, Validierungs- und Testdatensatz aufgeteilt, und ein weiteres Jahr mit getrennten Daten wurde zum Testen verwendet. Dies unterscheidet sich von unserer Methode, bei der die Testdaten vollständig zeitlich getrennt sind, und dies wurde teilweise gewählt, weil anfängliche Analysen an Modellen, die mit Daten aus demselben Sonnenzyklus trainiert und getestet wurden, geringere Fehler aufwiesen, sich jedoch als nicht so gut erwiesen neue Daten. Yang et al. ([2018](#)) haben auch ähnliche Eingabedaten verwendet,

einschließlich einer als Feature enthaltenen 27-Tage-Persistenzvariable. Ein direkter Vergleich der Ergebnisse ist vor allem aufgrund der Definition der Trainings- und Testdatensätze in dieser Studie schwierig. Im Gegensatz zu ihrer Verwendung eines komplexeren neuronalen Netzes haben wir uns aufgrund der schnellen Rechenzeiten und der einfacheren Implementierung gepaart mit starken Möglichkeiten zur detaillierten Modellinterpretation für die Verwendung eines GBR entschieden. Auf diese Weise bietet es eine effiziente Methode, die in Zukunft leicht angepasst werden kann, z. B. um auf neue Sonnenzyklusdaten trainiert zu werden.

Eine aktuelle Studie, Chandorkar et al. ([2020](#)), nähert sich demselben Problem mit einem komplexeren maschinellen Lernansatz, der auf neuronalen Netzen basiert. In unserer Studie wurde die Unsicherheit in der Zeit, die der Sonnenwind benötigt, um von der Sonne zur Erde zu reisen, berücksichtigt, indem alle möglichen Zeitfenster von 2 bis 5 Tagen eingeschlossen wurden. Chandorkar et al. ([2020](#)) baute stattdessen einen dynamischen Zeitverzögerungs-Regressionsalgorithmus um dieses Timing-Problem herum, der es der Methode ermöglichte, Zeitverzögerungen ohne eine explizit definierte Grundwahrheit zu lernen und zu berücksichtigen. Ein weiterer Unterschied ist die zeitliche Auflösung: Ihr Modell arbeitet mit stündlichen Vorhersagen, unseres hat eine Auflösung von 3,64 h. In Bezug auf die Genauigkeit präsentiert ihr Papier vorläufige Ergebnisse für einen definierten Zeitraum, Carrington-Rotation Nr. 2077, mit MAE- und RMSE-Werten von 60,19 km/s und 72,64 km/s. Die Werte für unser Modell liegen für den gleichen Zeitbereich bei 45,19 km/s und 56,75 km/s. Der Vergleich zeigt, dass unser Modell besser abschneidet, aber da wir nur mit einer Carrington-Rotation vergleichen können, stellt dies keinen endgültigen Vergleich der beiden Modelle dar.

5 Zusammenfassung

In dieser Studie haben wir einen Ansatz zur Vorhersage der umgebenden Sonnenwindbedingungen in der Nähe der Erde vorgestellt. Insbesondere schlagen wir vor, die statische WSA-Beziehung an der inneren Grenze der heliosphärischen Modelldomäne durch eine maschinelle Lerntechnik zu ersetzen, die direkt das, was in der Nähe der Sonne passiert, mit dem in Verbindung bringt, was in der Nähe der Erde passiert. Wir finden heraus, dass die Merkmale, die üblicherweise in empirischen Techniken zum Spezifizieren von Sonnenwindbedingungen in der Nähe der Sonne verwendet werden, nämlich der Flussröhren-Ausdehnungsfaktor f_p und der Abstand zur koronalen Lochgrenze d , sind die entscheidenden Merkmale. Obwohl wir uns im ersten Teil auf die Verbesserung der Genauigkeit konzentrieren, bietet unsere vorliegende Untersuchung ein neues Forschungswerkzeug, um das anstehende Problem der Rangfolge der relativen Bedeutung von f_p und d anzugehen, *und* eröffnet vielversprechende *Forschungswege* für die Zukunft.

Dies ist das erste Mal, dass ADAPT-Realisierungen mit einer Methode des maschinellen Lernens kombiniert wurden, um eine Methode zur Optimierung ihrer Nutzung anzubieten. Obwohl es möglich ist, alle ADAPT-Realisierungen zu verwenden, um den umgebenden Sonnenwindfluss vorherzusagen, stellen wir fest, dass eine Kombination einiger weniger Realisierungen die besten Ergebnisse liefert.

Das endgültige Modell liefert eine Vorhersage des umgebenden Sonnenwindes mit einer Vorlaufzeit von im Idealfall 4,5 Tagen, wobei nur Daten innerhalb von 60° westlich des Sonnenmeridians genommen werden, um mögliche Ungenauigkeiten aufgrund fehlender Bildgebung und Modellprojektion zu eliminieren größere Längen. Diese Vorlaufzeit könnte bei einer Mission am Sonne-Erde-Lagrange-Punkt 5 (−60° von der Erde) auf 9 Tage oder 14

Tage verlängert werden, wenn eine ganze Hälfte der magnetischen Sonnenkarte von -180° bis zum Meridian 0° liegt gebraucht.

Mit den präsentierten Ergebnissen schließen wir, dass die Technik des maschinellen Lernens, für die der Code Open-Source bereitgestellt wird, einen robusten und schnellen Ansatz zur Vorhersage der Sonnenwindgeschwindigkeit in der Nähe der Erde ermöglicht. Der Algorithmus ist leicht auf andere Solarwind-Frameworks übertragbar und stellt daher einen wichtigen Beitrag für die Weltraumwetter-Community dar und kann als Maßstab für die zukünftige Entwicklung numerischer Umgebungs-Sonnenwindmodelle dienen. In einem breiteren Kontext legt diese Studie den Grundstein für zukünftige Arbeiten zu diesem Thema, die sich mit der Verbesserung der Modellierung von Sonnenwindbedingungen in der Nähe der Sonne befassen werden (siehe z. B. Yang & Shen, 2019) [und](#) wichtige Beiträge für MHD-Codes liefern.

Danksagungen

RL Bailey, MA Reiss, C. Mostl, UV Amerstorfer, T. Amerstorfer, AJ Weiss und J. Hinterreiter danken dem Austrian Science Fund (FWF): P31659-N27, J4160-N27, P31521-N27 und P31265-N27. MAR dankt dem CCMC der NASA für die Reiseunterstützung. Ein Teil dieser Arbeit wurde während eines Forschungsaufenthalts bei der NASA Goddard im Dezember 2019 durchgeführt. Details dazu, wo die in dieser Studie verwendeten Daten sowie der Entwicklungscode zu finden sind, finden Sie in Abschnitt [6](#). Die Autoren möchten auch dem Herausgeber und den anonymen Gutachtern für ihre Hilfe bei der Verbesserung dieser Arbeit danken.

Offene Forschung