

Julia Grochowska¹

Studenckie Koło Naukowe Zakładu Rolnictwa, Akademia Bialska im. Jana Pawła II,
Biała Podlaska

prof. dr hab. Marcin Weiner²

Akademia Bialska im. Jana Pawła II, Biała Podlaska

ZASTOSOWANIE UCZENIA MASZYNOWEGO DO WCZESNEJ DETEKCJI STRESU U POMIDORÓW (*SOLANUM LYCOPERSICUM*) W UPRAWACH SZKLARNIOWYCH NA PODSTAWIE WYDZIELANYCH LOTNYCH ZWIĄZKÓW ORGANICZNYCH

APPLICATION OF MACHINE LEARNING FOR EARLY DETECTION OF STRESS IN TOMATO PLANTS (*SOLANUM LYCOPERSICUM*) IN GREENHOUSE CULTIVATION BASED ON EMITTED VOLATILE ORGANIC COMPOUNDS

Streszczenie

Wobec rosnących wymagań dotyczących produkcji rolniczej oraz potrzeby ograniczenia stosowania chemicznych środków ochrony roślin, coraz większego znaczenia

¹ <https://orcid.org/0009-0006-9441-4002>, e-mail: grochowska23375@stud.akademiabialska.pl

² <https://orcid.org/0000-0001-9288-0823>

Grochowska, J., Weiner, M. (2026). Zastosowanie uczenia maszynowego do wczesnej detekcji stresu u pomidorów (*Solanum lycopersicum*) w uprawach szklarniowych na podstawie wydzielanych lotnych związków organicznych. W: A. Siedlecka, M. Pyra (red.), *AI 360°: innowacje i zastosowania sztucznej inteligencji w gospodarce, społeczeństwie i nauce* (s. 96-118). Biała Podlaska: Akademia Bialska im. Jana Pawła II. https://doi.org/10.29316/9788368103366_6

nabierają metody umożliwiające wczesne i precyzyjne wykrywanie stresu u roślin. Rośliny pomidora (*Solanum lycopersicum*) emitują charakterystyczne zestawy lotnych związków organicznych (LZO), których profil ulega zmianie pod wpływem różnych bodźców biotycznych i abiotycznych. W prezentowanej pracy, z wykorzystaniem nadzorowanego uczenia maszynowego, podjęto próbę weryfikacji wstępnej hipotezy mówiącej, że zmiany w emisji LZO mogą odzwierciedlać działanie odmiennych czynników stresowych. Takie podejście mogłoby znaleźć zastosowanie w systemach wczesnego wykrywania zagrożeń wpływających na wielkość i jakość plonu, opartych na sieciach czujników oraz algorytmach przetwarzających i interpretujących dane. Rozwiązania tego typu szczególnie dobrze wpisują się w warunki upraw szklarniowych, gdzie łatwiej o kontrolę środowiska i wiarygodny odczyt sygnałów. W oparciu o dane z publikacji naukowych zbudowano niewielki model drzewa decyzyjnego w ramach strategii *Proof-of-Concept*, którego działanie potwierdziło, że zmienność emisji wybranych grup związków lotnych może stanowić podstawę do rozróżniania analizowanych kategorii stresu, pomimo istotnych ograniczeń wynikających ze zróżnicowania źródeł i protokołów badawczych.

Słowa kluczowe: lotne związki organiczne, stres roślin, uczenie maszynowe

Abstract

In response to increasing demands on agricultural production and the need to reduce the use of chemical plant protection products, methods enabling the early and accurate detection of plant stress are gaining importance. Tomato plants (*Solanum lycopersicum*) emit characteristic sets of volatile organic compounds (VOCs), the composition of which changes under the influence of various biotic and abiotic factors. In this study, supervised machine learning was used to examine the preliminary hypothesis that alterations in VOC emission profiles may reflect the action of different stressors. Such an approach could be applied in early warning systems designed to detect threats that reduce yield quantity and quality, relying on sensor networks and data-processing systems utilising artificial intelligence algorithms. These solutions may be particularly useful in greenhouse cultivation, where controlled conditions allow for more reliable signal detection. Based on experimental data reported in scientific publications, a small decision-tree model was developed as a Proof-of-Concept. Its performance indicated that variations in the emission of selected VOCs may provide a basis for distinguishing between the stress categories considered, despite methodological limitations resulting from the heterogeneity of available studies and protocols.

Keywords: volatile organic compounds, plant stress, machine learning

Wstęp

W kontekście rosnącego światowego zapotrzebowania na żywność, ściśle powiązanego ze wzrostem globalnej populacji i poziomu wymagań konsumentskich, współczesne rolnictwo mierzy się z istotnymi wyzwaniami dotyczącymi bezpieczeństwa żywnościowego. Coraz wyższe oczekiwania rynku względem produkcji rolnej nasilają problem nierozważnego stosowania środków ochrony roślin i nawozów sztucznych w rolnictwie, niosąc poważne konsekwencje dla zdrowia publicznego (Gargiulo i in., 2025). Dzieje się tak głównie dlatego, że w rolnictwie przemysłowym najszybszą i najłatwiej dostępną metodą minimalizacji strat jest stosowanie chemii rolniczej. Pozwala ona na możliwie najszybsze eliminowanie przyczyn lub skutków stresów roślin, warunkowanych zarówno przez czynniki biotyczne, jak i abiotyczne. Gospodarstwa przemysłowe nastawione są na maksymalizację wydajności i minimalizację kosztów jednostkowych, stąd zamiast prowadzenia skrupulatnego monitoringu stanu roślin i doboru zabiegów w sposób ściśle wynikających z uzasadnionych potrzeb, wielu producentów rolnych decyduje się na stosowanie stałych, sprawdzonych w swojej praktyce procedur opartych na aplikacji nieobojętnych dla zdrowia człowieka i środowiska środków chemicznych (Deguine i in., 2021).

Kompromisowym rozwiązaniem jest prowadzenie uprawy w sposób integrowany. Przenosi on punkt ciężkości z działań szablonowych i reaktywnych na odpowiedzialną prewencję oraz interwencje celowane, uzależnione od faktycznej presji agrofagów. Nadrzędnym celem tego silnie promowanego przez Unię Europejską systemu jest zachowanie równowagi pomiędzy wysokością plonów, zdrowiem roślin a ochroną środowiska. W 2009 r. dyrektywa 2009/128/WE zobowiązała państwa członkowskie do wspierania rolników w przechodzeniu na integrowaną ochronę roślin (Dyrektywa 2009/128/WE, 2009). W wyniku implementacji przepisów unijnych od 1 stycznia 2014 r. w Polsce stosowanie integrowanej ochrony roślin stało się obowiązkowe dla profesjonalnych użytkowników środków ochrony roślin. Za użytkownika profesjonalnego uznaje się osobę fizyczną, która stosuje te preparaty w celach innych niż własne, niezarobkowe potrzeby, a więc przede wszystkim w ramach działalności gospodarczej lub zawodowej, w tym w rolnictwie i leśnictwie (Ustawa z dnia 8 marca 2013 r. o środkach ochrony roślin). Danego pestycydu używamy tylko wtedy, gdy monitoring (obserwacje, pułapki, progi ekonomicznej szkodliwości) jednoznacznie

wskaże, że populacja agrofaga osiągnęła poziom, przy którym spodziewane straty gospodarcze przewyższą koszt zabiegu. Odejście od powszechnego stosowania środków ochrony roślin o szerokim spektrum działania (ogólnobójczych) na rzecz celowanych i precyzyjnych zabiegów nie tylko minimalizuje negatywny wpływ na środowisko i organizmy niebędące celem, ale także zapobiega rozwojowi odporności u patogenów i szkodników, jednocześnie znacząco redukując obciążenie żywnościowe pozostałościami chemicznymi.

W praktyce wdrożenie tych zasad napotyka jednak na wyzwania, zwłaszcza w przypadku gospodarstw wielkopowierzchniowych, gdzie prowadzenie monitoringu stanu plantacji w czasie rzeczywistym jest niezwykle trudne (Deguine i in., 2021). Kompleksowy nadzór wymagałby bowiem jednoczesnego kontrolowania abiotycznych warunków siedliskowych oraz obserwacji pod kątem występowania licznych i zróżnicowanych grup organizmów szkodliwych. Należą do nich zarówno mikroorganizmy (bakterie, wirusy, grzyby), jak i bezkręgowce, w tym owady, nicienie czy roztocza. Wśród tych grup klasyfikuje się ogromną liczbę odmiennych gatunków agrofagów, których prawidłowa identyfikacja wymaga zaangażowania, wiedzy i doświadczenia (Gougherty, Davies, 2021).

Istnieje jednak możliwość wykorzystania współczesnej wiedzy o biologii roślin uprawnych do opracowywania strategii detekcji subtelnych sygnałów stresu, które są przez nie manifestowane już na jego bardzo wczesnym etapie, a nawet w ramach mechanizmów preadaptacyjnych. Zaawansowane czujniki są w stanie rejestrować różnego rodzaju sygnały manifestowane przez rośliny, a zintegrowane z nimi systemy informatyczne, często oparte o sztuczną inteligencję, przekształcać je w informacje czytelne dla człowieka. W takich systemach zastosowane mogą być przykładowo matryce sensorów (tzw. elektroniczne nosy), które dostarczają molekularne „odciski palców” emitowanych przez rośliny lotnych związków organicznych (LZO) (Gan i in., 2023). Są to wyspecjalizowane metabolity o małej masie cząsteczkowej (50-200 Da) i wysokiej prężności par w temperaturze otoczenia, co umożliwia im łatwe przechodzenie do fazy gazowej i dyfuzję w atmosferze (Peñuelas, Llusia, 2001). Odgrywają kluczową rolę w komunikacji roślin i sygnalizacji obronnej. Emisja LZO wzrasta w warunkach stresowych, takich jak uszkodzenia mechaniczne, atak owadów czy infekcja. Przykładowo, rutynowe zabiegi pielęgnacyjne, jak usuwanie starych liści, zwiększają emisję n-heksanal i (E)-2-heksenal (Gargiulo

i in., 2025). Możliwość nieinwazyjnego „podsluchiwania” chemicznego języka roślin, za pomocą którego komunikują one stres, otwiera drogę do opracowania nowych technologii pozwalających na kontrolę stanu roślin w stanie rzeczywistym, a co za tym idzie: natychmiastowych, celowanych interwencji.

O ile monitoring i analiza profilu LZO w skali uprawy polowej są bardzo trudne, o tyle kontrolowane środowisko szklarni stwarza idealne warunki do wdrożenia takich rozwiązań, przykładowo w uprawach pomidora (*Solanum lycopersicum* L.). Jest to roślina o wysokiej wartości ekonomicznej i stanowi kluczowe źródło pożywienia na świecie (Martina i in., 2021). Jednocześnie jest to ważny organizm modelowy w badaniach podstawowych i stosowanych. Dla pełnego wykorzystania potencjału rozwijających się technologii rejestrowania LZO duże znaczenie ma odpowiedź na pytanie jakie związki powinniśmy wykrywać w uprawach w celu identyfikacji rodzaju stresu roślin. Czy większe znaczenie będzie mieć rozpoznawanie pojedynczych markerów, pełnych profili emisji, czy może wzorców wydzielania poszczególnych związków w okresach czasowych? W literaturze dostępne są informacje dotyczące różnic w składzie LZO uwalnianych pod wpływem odmiennych bodźców biotycznych i abiotycznych działających na pomidory. Różnice te warunkowane są uruchamianiem osobnych ścieżek obronnych i sygnałowych, co rodzi potencjał do ustalenia jakich specyficznych emisji powinniśmy się spodziewać w trakcie wystąpienia danego zagrożenia, niezależnie od tego, czy będzie ono wywołane żerowaniem konkretnego owada, zasoleniem gleby, nieodpowiednią temperaturą, czy rozwijającą się infekcją grzybową. To właśnie zagadnienie stanowi główny problem badawczy oraz punkt wyjścia niniejszej pracy, której celem było zastosowanie nadzorowanego uczenia maszynowego do budowy modelu drzewa decyzyjnego klasyfikującego rodzaj stresu pomidora zwyczajnego na podstawie wzrostu emisji poszczególnych związków lotnych.

Materiał i metody

W celu opracowania prototypowego modelu dokonano przeglądu literatury naukowej, na podstawie której stworzono bazę danych. Zidentyfikowano i przeanalizowano 33 publikacje badawcze dokumentujące profile emisji LZO u roślin pomidora poddanych różnym rodzajom stresu. Zebrane dane podzielone na 54 przypadki uporządkowano w formie ustrukturyzowanej macierzy

danych. W przyjętym schemacie każdy wiersz odpowiadał pojedynczemu eksperymentowi, a kolumny opisane były przez 186 zmiennych, reprezentujących poszczególne związki lotne. Aby uchwycić zmianę emisji, przyjęto system binarny, gdzie wartość „1” rejestrowała zwiększoną emisję danego LZO w porównaniu do roślin kontrolnych, natomiast wartość „0” obejmowała zarówno brak wzrostu emisji danego LZO, jak i brak jego raportowania w analizowanej publikacji. Podejście to upraszczało integrację danych literaturowych, jednak może prowadzić do niedoszacowania znaczenia związków rzadziej raportowanych. Wykorzystanie modelu drzewa decyzyjnego w prezentowanym badaniu zostało podyktowane jego wysoką interpretowalnością, która pozwala na prześledzenie ścieżki decyzyjnej i identyfikację konkretnych związków LZO o największym znaczeniu diagnostycznym dla danego typu stresu oraz odpornością na nieistotne zmienne. Dodatkowo, przy stosunkowo niewielkim zbiorze danych wejściowych, drzewa decyzyjne są mniej podatne na nadmierne dopasowanie w porównaniu do bardziej złożonych modeli (np. sieci neuronowych) i skutecznie radzą sobie z identyfikacją nieliniarnych zależności w danych (Liu i in., 2004). Dane wejściowe opisano w Tabelach 1 i 2.

Tabela 1. Dane wejściowe: czynniki biotyczne

Odniesienie do literatury	Czynnik wywołujący stres (gatunek)	Kategoria czynnika	Związki lotne, których emisja wzrosła pod wpływem czynnika wywołującego stres
López-Gresa i in., 2017	<i>Pseudomonas syringae</i> DC3000 pv. tomato.	bakteria	salicylan etylu, salicylan metylu, salicylaldehyd, α -pinen, α -felandren, β -felandren, limonen, p-cymen
Arafa i in., 2022	<i>Phytophthora infestans</i> , gatunek grzybopodobny wywołujący zarazę ziemniaka	legniowiec grzybopodobny	3,4,5,7-tetrametoksyflawon, skopoletyna, nabilon, α -tokoferol
Jansen i in., 2009	<i>Botrytis cinerea</i> , gronowiec szary, wywołujący chorobę szara pleśń	grzyb	α -pinen, α -felandren, β -felandren, limonen, 2-karen, 1-penten-3-ol, (Z)-heks-3-enal, (Z)-3-heksen-1-ol, (E)-heks-2-enal, octan (Z)-3-heksen-1-ylu
Hernández-Aparicio i in., 2021	<i>Fusarium oxysporum</i> , wywołujący kompleks chorób nazywanych zgorzelami lub fuzariozami	grzyb	salicylan etylu, salicylan metylu, pentan-2-on, 2-nonenal, heksan-2-on, heptan-2-on, heptan-3-on, but-3-en-2-on, butanal, butan-2-on
Nawrocka i in., 2022	<i>Botrytis cinerea</i> , gronowiec szary, wywołujący chorobę szara pleśń	grzyb	salicylan etylu, salicylan metylu, fenol, heksanal, 4-metyloheksan-3-ol, 2-etyloheksan-1-ol, heks-2-en-1-ol, 1-(2-hydroksyfenylo)etanon, (E)-heks-2-enal, heksan-1-ol, 2-metylobenzaldehyd, acetofenon, salicylan hept-4-en-2-ylu, 2-metylofenol
Kasal i in., 2015	<i>Botrytis cinerea</i> , gronowiec szary, wywołujący chorobę szara pleśń	grzyb	salicylan metylu, β -kariofilen, (Z)-3-heksen-1-ol, (E)- β -ocymen, α -kopaen, walencen, aristolen, α -terpinen, izomaślan (Z)-3-heksenyli, δ -elemen, β -selinen
Kasal i in., 2015	<i>Oidium neolycopersici</i> , grzyb wywołujący chorobę mączniak prawdziwy pomidora	grzyb	β -kariofilen, (Z)-3-heksen-1-ol, α -kopaen, α -terpinen
Tomescu i in., 2017	<i>Botrytis cinerea</i> , gronowiec szary, wywołujący chorobę szara pleśń	grzyb	salicylan metylu, (Z)-3-heksen-1-ol, α -terpinen, heksanal, 2-hydroksyacetofenon, (E)-heks-2-enal

Odniesienie do literatury	Czynnik wywołujący stres (gatunek)	Kategoria czynnika	Związki lotne, których emisja wzrosła pod wpływem czynnika wywołującego stres
Kasal-Slavik i in., 2017	<i>Botrytis cinerea</i> , gronowiec szary, wywołujący chorobę szara pleśń	grzyb	salicylan metylu, β -felandren, limonen, (Z)-heks-3-enal, (Z)-heks-3-en-1-ol, propanian (Z)-heks-3-en-1-ylu, α -kopaen, β -ocymen, 4,8,12-trimetylotrideka-1,3,7,11-tetraen (TMTT), heksanal, (E)-2-heksenal, (E, E)-2, 4-heksadienal, 2-penten-1-ol, masłan (Z)-heks-3-en-1-ylu, pentanian (Z)-heks-3-en-1-ylu, izomasłan (Z)-heks-3-en-1-ylu
Kasal-Slavik i in., 2017	<i>Oidium neolycopersici</i> , grzyb wywołujący chorobę mączniak prawdziwy pomidora	grzyb	α -kopaen
Ghosh i in., 2022	TYLCV, wirus żółtej kędzierzawości liści pomidora	wirus	gwajakol, 1,3-dimetylobenzen, 2-dimetoksybenzen, fenol, 1-oktanol, kwas 9-heksadekenowy, palmitoleinian metylu
Spanò i in., 2023	wirus PVY (Y ziemniaka)	wirus	salicylan metylu, β -linalol, 1-penten-3-ol, (E)-3-heksen-1-ol, (Z)-3-heksen-1-ol, alkohol benzylowy, α -kopaen, gwajakol, 3-pentanon, (E)-2 heksen-1 ol, α -terpinen, benzaldehid, heksanal, (E)-heks-2-enal, heksan-1-ol, (E,E)-heksa-2,4-dienal, heks-3-enal, octan heksen-1-ylu, 2-metylo-pentan-1-ol, (Z)-pent-2-en-1-ol, pent-1-en-3-ol, pentan-1-ol, alkohol benzylowy, 2-fenylloctanol, nonanian metylu, (E)-2-heksenian metylu, 6-metylo-5-hepten-2-on, 2-etylofuran, 2-pentylofuran, o-gwajakol
Sun i in., 2010	<i>Meloidogyne incognita</i> , nicienie wywołujący chorobę potłudniowy guzaki korzeniowy	nicień	α -pinen, α -felandren, β -felandren, karweol, p-cymen, β -mircen, kamfen
Cui i in., 2019	<i>Myzus persicae</i> , mszyca brzo-skwinio-ziemniaczana	owad wysysający sok	α -pinen, α -felandren, β -linalol, karweol, kariofilen
Silva i in., 2017	<i>Bemisia tabaci</i> , mączlik ostroskrzydły	owady wysysający sok	salicylan metylu, pent-1-en-3-ol, pentan-3-ol, (E)-4-oksoheks-2-enal, α -kopaen, β -kopaen, walencen, aristolochen, (Z)-pent-2-en-1-ol, konofityrona, β -cyklocytral

Odniesienie do literatury	Czynnik wywołujący stres (gatunek)	Kategoria czynnika	Związki lotne, których emisja wzrosła pod wpływem czynnika wywołującego stres
Ángeles i in., 2012	<i>Trialeurodes vaporariorum</i> , mączlik szklarniowy	owad wysysający sok	salicylan metylu, α -pinen, β -kariofilen, α -humulen, α -gurjunen, izolenden, dekan, (E/Z)- β -ocymen, tlenek kariofilenu, α -muurolen, aromadendren, δ -kadinen, gerkakren D, aristolen,
Meijer i in., 2023	<i>Tetranychus urticae</i> , przędziorzek chmielowiec	roztoczek wysysający sok	linalol, (Z)-heks-3-en-1-ol, (E)- β -jonon
Ghosh i in., 2022	<i>Bemisia tabaci</i> , mączlik ostroskrzydły	owad wysysający sok	gwajakol, 1-oktanol, kwas 7,10,13-heksadekatrienowy
Islam i in., 2017	<i>Bemisia tabaci</i> , mączlik ostroskrzydły	owad wysysający sok	β -pinen, β -kariofilen, β -felandren, p-cymen, α -kopaen, (+)-4-karen, α -terpinen
Kasal i in., 2015	<i>Myzus persicae</i> , mszyca brzo-skwinioowo-ziemniaczana	owad wysysający sok	salicylan metylu, α -terpinen, 4,8,12-trimetylotrideka-1,3,7,11-tetraen (TMTT)
Kasal i in., 2015	<i>Trialeurodes vaporariorum</i> , mączlik szklarniowy	owad wysysający sok	(Z)-3-heksen-1-ol, α -terpinen
Tomescu i in., 2017	<i>Trialeurodes vaporariorum</i> , mączlik szklarniowy	owad wysysający sok	salicylan metylu, β -kariofilen, α -kopaen, 4,8,12-trimetylotrideka-1,3,7,11-tetraen (TMTT)
Tomescu i in., 2017	<i>Myzus persicae</i> , mszyca brzo-skwinioowo-ziemniaczana	owad wysysający sok	salicylan metylu, α -terpinen, 4,8,12-trimetylotrideka-1,3,7,11-tetraen (TMTT)
Kasal-Slavik i in., 2017	<i>Myzus persicae</i> , mszyca brzo-skwinioowo-ziemniaczana	owad wysysający sok	salicylan metylu
Silva i in., 2017	<i>Tuta absoluta</i> , skośnik pomidorowy	owad gryzący	salicylan metylu, β -kariofilen, linalol, α -humulen, pent-1-en-3-ol, pentan-3-ol, (E)-pent-2-enal, (Z)-heks-3-en-1-ol, octan (Z)-heks-3-en-1-ylu, propionian (Z)-heks-3-en-1-ylu, (Z)-jazon, alkohol benzylowy, indol, antranilan metylu, maślan benzylu, eugenol, (E)- β -ocymen, (E)-DMNT, krotonian (Z)-heks-3-en-1-ylu, angelan (Z)-heks-3-en-1-ylu, octan (Z)-pent-2-en-1-ylu, maślan (Z)-pent-2-en-1-ylu, α -humulen

Odniesienie do literatury	Czynnik wywołujący stres (gatunek)	Kategoria czynnika	Związki lotne, których emisja wzrosła pod wpływem czynnika wywołującego stres
D'Esposito i in., 2023	<i>Tuta absoluta</i> , skośnik pomidorowy	owad gryzący	salicylan metylu, ocymen, δ -3-karen, γ -terpinen
Vescio i in., 2022	<i>Tuta absoluta</i> , skośnik pomidorowy	owad gryzący	β -pinen, α -pinen, β -kariofilen, β -felandren, α -kopaen, (E)-2-heksen-1-ol, (2E)-2-heksen-1-yl propionian, propionian heksylu, (+)-4-karen, terpinolen
Lin i in., 2022	<i>Helicoverpa zea</i>	owad gryzący	salicylan etylu, α -pinen, α -kariofilen, β -kariofilen, alfa-humulen, (Z)-3-heksen-1-ol, (Z)-jasmon, indol, α -kopaen, alloocymen, β -ocymen, b-mircen, α -humulen, 4,8,12-trimetylotrideka-1,3,7,11-tetraen (TMTT), springen, 6,9-gwajadien
Chen i in., 2021	<i>Tuta absoluta</i> , skośnik pomidorowy	owad gryzący	(E)-heks-3-en-1-olowy (E)-2-metylobut-2-enian, (E)-heks-3-en-1-ol, (Z)-hex-3-en-1-ol, β -cyklocytral, 2-pentylfuran, 2,6-dimetylocykloheksan-1-on, β -izo-metylojonon, β -safranal, nerolidol, kwas but-2-enowy, 2-etylobenzaldehyd, 2,6-dimetylocykloheksanol, 1-okten-3-ol
Maes i in., 2003	<i>Spodoptera littoralis</i> , sówka bawełnowka egipska	owad gryzący	β -pinen, δ -kariofilen, β -kariofilen, β -linalol, indol
Zebelo i in., 2014	<i>Spodoptera exigua</i> , światłówka naziemnica	owad gryzący	salicylan metylu, γ -terpinen, (E)- β -kariofilen, β -linalol, alfa-humulen, (Z)-3-heksen-1-ol, octan (Z)-heks-3-en-1-ylu, γ -terpinen, (E)-2-heksenal, δ -elemen, β -elemen, (Z)-heks-2-en-1-ol, 3-oktanol, nonanal, dekanal
Tomescu i in., 2017	<i>Spodoptera littoralis</i> , sówka bawełnowka egipska	owad gryzący	β -pinen, β -kariofilen, β -linalol, (Z)-heks-3-enal, indol, (E)-heks-2-enal, (Z)-heks-2-en-1-ol, octan (Z)-heks-3-en-ylu
Kergunteuil i in., 2021	<i>Tuta absoluta</i> , skośnik pomidorowy	owad gryzący	α -pinen, β -felandren, 2-karen
Raghava i in., 2010	<i>Spodoptera litura</i> , sówka bawełnowka azjatycka	owad gryzący	α -pinen, kariofilen, alfa-humulen, ocymen, b-mircen, terpinolen, karen, 3-metylobutanal

Odniesienie do literatury	Czynnik wywołujący stres (gatunek)	Kategoria czynnika	Związki lotne, których emisja wzrosła pod wpływem czynnika wywołującego stres
Farag i in., 2002	<i>Manduca sexta</i> , zawisak tytoniowy	owad gryzący	salicylan metylu, β -pinen, α -pinen, β -kariofilen, β -felandren, alfa-humulen, 2-karen, (Z)-heks-3-enal, 4,8,12-trimetylotrideka-1,3,7,11-tetraen (TMTT), heksanal, (E)-heks-2-enal, δ -elemen, (Z)-heks-2-en-1-ol, β -pinen, α -pinen, β -kariofilen, α -humulen, ocymen, α -terpinen, δ -elemen, octanian linalylu, sabinen
Disi i in., 2017	<i>Spodoptera exigua</i> , światłówka naziemnica	owad gryzący	

Tabela 2. Dane wejściowe: czynniki abiotyczne

Odniesienie do literatury	Czynnik wywołujący stres	Kategoria czynnika	Związki lotne, których emisja wzrosła pod wpływem czynnika wywołującego stres
Nagalingam i in., 2022	wysoka temperatura	stres termiczny	salicylan metylu, α -pinen, α -felandren, β -felandren, limonen, 2-karen, α -terpinen, 4,8,12-trimetylotrideka-1,3,7,11-tetraen (TMTT)
Copolovici i in., 2012	szok zimna	stres termiczny	α -pinen, α -felandren, β -kariofilen, β -felandren, 2-karen, (Z)-3-heksen-1-ol, β -ocymen, (E)-heks-2-enal, heksan-1-ol, β -elemen, heksa-1,4-dienal
Vescio i in., 2022	susza	stres wodny	α -humulen, α -terpinen, δ -terpinen
Pagadala Damodaram i in., 2021	stres wodny	stres wodny	α -pinen, β -felandren, (+)-4-karen, terpinolen, m-cymen, β -tujen
Pagadala Damodaram i in., 2021	umiarkowany stres wodny	stres wodny	etylobenzaldehyd, heksan-2,5-diol, 1-fenyl-1-buten, 4-(prop-2-enyl)fenol, dodekan, kwas dekanowy, fitan, 2,6,10-trimetylotetradekan, γ -butylo- γ -butyrolakton
Kasal i in., 2015	susza	stres wodny	(Z)-3-heksen-1-ol, β -ocymen, α -terpinen, 4,8,12-trimetylotrideka-1,3,7,11-tetraen (TMTT)
Tomescu i in., 2017	krytyczna susza	stres wodny	(Z)-3-heksen-1-ol

Odniesienie do literatury	Czynnik wywołujący stres	Kategoria czynnika	Związki lotne, których emisja wzrosła pod wpływem czynnika wywołującego stres
Maes i in., 2003	ciągłe oświetlenie	stres świetlny	β -kopaen
Tomescu i in., 2017	ciągłe oświetlenie	stres świetlny	β -kopaen
Sun i in., 2010	podwyższony poziom CO ₂	stres gazowy	α -pinen, karweol, p-cymen
Kasal i in., 2015	ekspozycja na ozon	stres gazowy	salicylan metylu, (E)- β -ocymen, izomaślan (Z)-3-heksenyłu
Mina i in., 2010	ekspozycja na ozon	stres gazowy	izopren
Tomescu i in., 2017	ekspozycja na ozon	stres gazowy	izopren
Vescio i in., 2022	niedobór azotu	stres odżywczy	α -humulen, α -terpinen, δ -terpinen
Kergunteuil i in., 2021	niedobór azotu	stres odżywczy	salicylan metylu
Tomescu i in., 2017	zasolenie gleby	stres chemiczny	β -felandren, 2-karen, (Z)-3-heksen-1-ol
Zhang i in., 2018	zasolenie gleby (NaCl)	stres chemiczny	β -felandren, kariofilen, (-)-kopaen, mircen, (+)-4-karen, terpinolen, δ -elemen, geranyloaceton, α -kubeben, kwas heksadekanowy, kwas oktadekanowy
Vehar i in., 2025	zanieczyszczenia w roztworze odżywczym w uprawie hydroponicznej (CECs)	stres chemiczny	octanian metylu, ftalan dietylu, benzenonitryl, kwas heptanowy, nonanediol dimetylu

Wyniki

Z analizy pozyskanych artykułów naukowych wyodrębniono przypadki stresów roślinnych, które sklasyfikowano według rodzaju czynników wywołujących je na stresy biotyczne i abiotyczne. Stres biotyczny obejmował czynniki powodowane przez organizmy żywe, w tym bakterie *Pseudomonas syringae* pv. *tomato*, patogeny grzybowe: *Botrytis cinerea* (gatunek wywołujący chorobę szara pleśń) *Fusarium oxysporum* (wywołujący fuzariozę), *Oidium neolycomper-sici* (wywołujący chorobę mączniak prawdziwy), *Phytophthora infestans* (wywołujący zarazę ziemniaka), wirusy: wirus żółtej kędzierzawości liści pomidora (TYLCV), wirus Y ziemniaka, nicien *Meloidogyne incognita* (wywołujący chorobę guzak korzeni), owady gryzące i żujące, takie jak skośnik pomidorowy (*Tuta absoluta*), światłówka naziemnica (*Spodoptera exigua*), *Helicoverpa zea*, zawisak tytoniowy (*Manduca sexta*), sówka bawełnówka azjatycka (*Spodoptera litura*), sówka bawełnówka egipska (*Spodoptera littoralis*), a także owady i roztocza ssące i wysysające sok, m.in. mszyca brzoskwińowo-ziemniaczana (*Myzus persicae*), mączlik ostroskrzydły (*Bemisia tabaci*), mączlik szklarniowy (*Trialeurodes vaporariorum*) oraz przedziorek chmielowiec (*Tetranychus urticae*). Stresy abiotyczne obejmowały czynniki środowiskowe, w tym stres wodny, stres termiczny, a także stresy świetlne, gazowe, chemiczne i odżywcze, jak podwyższony CO₂, zasolenie gleby czy niedobór azotu.

Na etapie wstępnej, eksploracyjnej analizy uzyskanego zbioru danych zidentyfikowano pewne ograniczenia związane ze zbyt niską reprezentacją części przypadków oraz dużą niespójnością profili emisji LZO nawet w ramach tej samej kategorii stresu. Źródłem tego zróżnicowania jest natura analizy, każda z 33 prac stosowała inne protokoły badawcze (m.in. definiując inaczej intensywność i czas trwania stresu). Dla algorytmu uczenia maszynowego taka niejednorodność danych stanowi wyzwanie dla procesu uczenia modelu. Drugim wyzwaniem był problem niskiej specyficzności sygnału i nakładania się profili LZO pomiędzy różnymi klasami stresu. Wobec zidentyfikowanych wyzwań, odstąpiono od próby budowy „uniwersalnego” klasyfikatora. Zamiast tego, przyjęto strategię *Proof-of-Concept* (PoC). W tym celu ograniczono zbiór danych do 27 przypadków z 22 prac badawczych w ramach trzech kategorii stresu, które z perspektywy przemysłowej są kluczowe, a z perspektywy biologicznej- zakładają odmienne ścieżki metaboliczne: Owady i roztocza ssące/

wysysające sok, owady gryzące/żujące ($n=12$), stres termiczny ($n=4$). Dodatkowo, usunięto z dalszej analizy wszystkie związki, które nie pojawiły się w żadnym z uwzględnionych przypadków stresu, pozostawiając 104 związki lotne.


Budowa modelu

Do budowy i walidacji modelu klasyfikacyjnego wykorzystano język programowania Python w interaktywnym środowisku Jupyter Notebook, które umożliwiło elastyczne prowadzenie analiz oraz bieżącą wizualizację wyników (Kluyver i in., 2016). Kluczowe etapy pracy opierały się na bibliotekach open-source szeroko stosowanych w analizie danych i uczeniu maszynowym. Pandas (The pandas development team, 2025) do przygotowania zbioru wejściowego, tj. wczytywania, oczyszczania oraz manipulacji danymi. Scikit-learn (Pedregosa i in., 2011) do budowy modelu klasyfikacyjnego, wykorzystano m.in. funkcję `train_test_split` do stratyfikowanego podziału danych na zbiór treningowy i testowy, przy czym proporcja wynosiła 70% danych do treningu i 30% do testowania, co zapewniło odpowiednią równowagę między możliwością nauczania modelu a rzetelną oceną jego generalizacji. Ponadto wykorzystano `DecisionTreeClassifier` do trenowania drzewa decyzyjnego oraz `accuracy_score` i `confusion_matrix` do oceny jakości predykcji na zbiorze testowym. Do wizualizacji wyników, w szczególności do przedstawienia końcowej struktury wytrenowanego drzewa decyzyjnego, wykorzystano bibliotekę Matplotlib (Hunter, 2007) w połączeniu z funkcją `plot_tree` dostępną w module `sklearn.tree`, co pozwoliło przedstawić model w formie intuicyjnego i czytelnego diagramu.

Implementacja i wyniki modelu klasyfikacyjnego

W procesie klasyfikacji badanych stresorów kluczowy atrybut decyzyjny stanowi α -humulen. Wzrost emisji tego związku, analizowany w węźle korzeniowym drzewa, identyfikowany jest jako predyktor o zerowej nieczystości (wskaźnik Giniego = 0,0) dla kategorii „Owady gryzące/żujące”. Oznacza to, że w oparciu o analizowane dane, sam fakt indukcji tego seskwiterpenu,

jest warunkiem wystarczającym do jednoznacznej klasyfikacji. Alternatywnie, klasa „Owady gryzące/żujące” może być również identyfikowana poprzez wzrost emisji δ -kariofilenu. Sygnał ten ujawnia się w ścieżce decyzyjnej, gdy nie stwierdza się indukcji ani α -humulenu, ani β -felandrenu, reprezentując zatem wtórny, alternatywny marker żerowania, również oparty na biosyntezie seskwiterpenów. Klasa „Stres cieplny/termiczny” definiowana jest przez jednoczesny wzrost emisji dwóch monoterpenów: β -felandrenu oraz α -felandrenu. Ta specyficzna koincydencja wskazuje na prawdopodobną, zsynchronizowaną aktywację szlaków biosyntezy tych monoterpenów w plastydach, stanowiącą odpowiedź na stres cieplny/termiczny. Z kolei klasa „Owady i roztocza ssące/wysysające sok” jest najczęściej klasyfikowana w sytuacji braku wzrostu któregośkolwiek z wyselekcjonowanych przez model związków markerowych (Rysunek 1).



Rysunek 1. Wizualizacja opracowanego drzewa decyzyjnego

Źródło: opracowanie własne.

Ewaluacja skuteczności klasyfikacji

Skuteczność modelu poddano ocenie na wcześniej niewidzianym zbiorze testowym, zachowując zasadę stratyfikacji. Osiągnięty poziom trafności wyniósł 55,56%. Należy podkreślić, że wynik ten jest istotnie wyższy od teoretycznego progu losowego, który dla problemu trójklasowego wynosi 33,3%. Różnica ta, sięgająca ponad 22 punkty procentowe, stanowi przesłankę, że

model nie dokonuje klasyfikacji w sposób czysto przypadkowy, lecz jest w stanie wychwycić i interpretować rzeczywiste, choć subtelne, wzorce w danych chemicznych.

Dyskusja

Analiza wytrenowanego modelu ujawniła, że kluczowym węzłem w hierarchicznej strukturze decyzyjnej, umożliwiającej wstępną identyfikację markerów, jest α -humulen. Jego podwyższona emisja jest tu charakterystyczna dla stresu indukowanego przez owady gryzące/ żujące, co znajduje uzasadnienie w literaturze przedmiotu. Zwiększona emisja α -humulenu w odpowiedzi na żerowanie owadów gryzących jest elementem indukowanej odpowiedzi obronnej roślin, często obserwowanym u pomidora. Mechanizm ten rozpoczyna się od uszkodzenia tkanek i kontaktu z elitorami obecnymi w płynach dostających się do rośliny podczas żerowania, do których należą m.in. wydzieliny z brzusznych gruczołów wywracanych gąsienic *Spodoptera exigua*, które znacząco zwiększają produkcję i emisję pewnych związków lotnych, w tym α -humulenu (Kutty, Mishra, 2023).

Model w procesie decyzyjnym uwzględnił również inne związki terpenowe, takie jak β -felandren, δ -kariofilen oraz α -felandren. Zostały one wykorzystane jako dodatkowe sygnały różnicujące, co sugeruje, że w dostępnych danych występowały pewne regularności w zwiększeniu ich emisji, które algorytm uznał za pomocne przy rozróżnianiu typów stresu. Należy jednak podkreślić, iż wybór tych konkretnych związków przez model nie musi odzwierciedlać ich fundamentalnego znaczenia jako biomarkerów, a raczej, że ich zmienność była wystarczająco informatywna, by wspierać proces klasyfikacji.

Uzyskana trafność na poziomie 55,56%, choć nieosiągająca wartości optymalnych dla bardzo dobrej klasyfikacji, musi być interpretowana w kontekście inherentnych wyzwań związanych z analizą danych biologicznych. Czynniki takie jak zróżnicowanie indywidualne między replikami roślinnymi, potencjalne nakładanie się szlaków sygnalizacyjnych w odpowiedzi na różne typy stresorów oraz bardzo ograniczona liczebność zbioru danych (która zwiększa ryzyko nadmiernego dopasowania modelu oraz ogranicza jego zdolność do generalizacji) znacząco utrudniają zadanie modelu. Ograniczeniem pracy jest również brak standaryzacji metod pomiarowych w analizowanych

publikacjach, co mogło wpływać na wykrywalność określonych związków. Biorąc pod uwagę te ograniczenia, fakt, że model był w stanie w ogóle wykroczyć poza próg losowości i zidentyfikować istotne biomarkery, świadczy o potencjale diagnostycznym zastosowanej metody. Dalszy rozwój badań wymaga przede wszystkim stworzenia spójnego korpusu danych pozyskanego w warunkach kontrolowanych, co pozwoli na pełniejszą i bardziej wiarygodną ocenę możliwości modelu. Kluczowe byłoby również oparcie analiz na dokładnych pomiarach stężeń, dzięki którym możliwe stanie się precyzyjniejsze uchwycenie różnic biologicznych między obserwowanymi stanami. Uzupełnieniem tych działań powinna być eksploracja bardziej zaawansowanych architektur uczenia maszynowego, mogących skuteczniej wydobywać subtelne wzorce związane ze stresem.

Wnioski

Przeprowadzone badanie potwierdziło, że profil emisji LZO może stanowić wartościowe źródło informacji diagnostycznej w kontekście wczesnej detekcji stresu u pomidorów w środowisku szklarniowym. Pomimo znaczącej heterogeniczności danych literaturowych i ograniczonej liczby spójnych obserwacji, opracowany prototypowy model drzewa decyzyjnego wykazał zdolność wychwytywania powtarzalnych wzorców charakterystycznych dla różnych kategorii stresu. Uzyskany wynik klasyfikacji na poziomie 55,56%, znacznie wyższym niż próg losowy, wskazuje, że nawet uproszczone, binarne odwzorowanie sygnałów pozwala modelowi identyfikować pewne związki o znaczeniu diagnostycznym.

Największą wartość predykcyjną wykazały terpeny, w szczególności seskwiterpen α -humulen, którego wzrost emisji okazał się markerem wysoce specyficznym dla stresu wywołanego przez owady gryzące/żujące. Również δ -kariofilen oraz wybrane monoterpeny (α - i β -felandren) pełniły istotną funkcję różnicującą, umożliwiając klasyfikację stresu termicznego. Jednocześnie obserwowany brak jednoznacznych wzorców emisji w odpowiedzi na żerowanie owadów ssących podkreśla ograniczenia wynikające z dostępnego zbioru danych oraz z wysokiej zmienności biologicznej reakcji roślin.

Wyniki badań wskazują, że algorytmy uczenia maszynowego analizujące wzorce emisji LZO mają potencjał diagnostyczny i mogą stanowić kluczowy

element systemów przetwarzających dane z czujników do wczesnego wykrywania stresu roślin z uwzględnieniem/rozróżnieniem jego przyczyny. Rozwój takiej technologii wymaga jednak opracowania rozbudowanych, standaryzowanych baz danych tworzonych w kontrolowanych warunkach eksperymentalnych. Niezbędne jest również wdrożenie bardziej precyzyjnych metod pomiaru stężeń związków lotnych oraz połączenie łatwo interpretowalnych modeli sztucznej inteligencji, takich jak drzewa decyzyjne, z bardziej zaawansowanymi algorytmami uczącymi się z dużych zbiorów danych. Dopiero takie podejście pozwoli określić pełną użyteczność profili emisji LZO jako wskaźników rodzaju stresu i stworzyć systemy detekcji zdolne do praktycznego zastosowania w monitoringu upraw szklarniowych.

Literatura

1. Ángeles López, Y. I., Martínez-Gallardo, N. A., Ramírez-Romero, R., López, M. G., Sánchez-Hernández, C., Délano-Frier, J. P. (2012). Cross-kingdom effects of plant-plant signaling via volatile organic compounds emitted by tomato (*Solanum lycopersicum*) plants infested by the greenhouse whitefly (*Trialeurodes vaporariorum*). *Journal of Chemical Ecology*, 38(11), 1376-1386. <https://doi.org/10.1007/s10886-012-0201-z>
2. Arafa, R. A., Kamel, S. M., Taher, D. I., Solberg, S. Ø., Rakha, M. T. (2022). Leaf extracts from resistant wild tomato can be used to control late blight (*Phytophthora infestans*) in the cultivated tomato. *Plants*, 11(14), 1824. <https://doi.org/10.3390/plants11141824>
3. Chen, L., Li, X., Zhang, J., He, T., Huang, J., Zhang, Z., Wang, Y., Hafeez, M., Zhou, S., Ren, X., Hou, Y., Lu, Y. (2021). Comprehensive metabolome and volatilome analyses in eggplant and tomato reveal their differential responses to *Tuta absoluta* infestation. *Frontiers in Plant Science*, 12, 757230. <https://doi.org/10.3389/fpls.2021.757230>
4. Copolovici, L., Kännaste, A., Pazouki, L., Niinemets, Ü. (2012). Emissions of green leaf volatiles and terpenoids from *Solanum lycopersicum* are quantitatively related to the severity of cold and heat shock treatments. *Journal of Plant Physiology*, 169(7), 664-672. <https://doi.org/10.1016/j.jplph.2011.12.019>
5. Cui, S., Inocente, E. A. A., Acosta, N., Keener, Harold. M., Zhu, H., Ling, P. P. (2019). Development of fast e-nose system for early-stage diagnosis of

- aphid-stressed tomato plants. *Sensors*, 19(16), 3480. <https://doi.org/10.3390/s19163480>
6. Deguine, J.-P., Aubertot, J.-N., Flor, R. J., Lescourret, F., Wyckhuys, K. A. G., Ratnadass, A. (2021). Integrated pest management: good intentions, hard realities. A review. *Agronomy for Sustainable Development*, 41(3), 38. <https://doi.org/10.1007/s13593-021-00689-w>
7. D'Esposito, D., Guadagno, A., Amoroso, C. G., Cascone, P., Cencetti, G., Michelozzi, M., Guerrieri, E., Ercolano, M. R. (2023). Genomic and metabolic profiling of two tomato contrasting cultivars for tolerance to *Tuta absoluta*. *Planta*, 257(3), 47. <https://doi.org/10.1007/s00425-023-04073-8>
8. Disi, J. O., Zebelo, S., Ngumbi, E., Fadamiro, H. Y. (2017). Cis-jasmone primes defense pathways in tomato via emission of volatile organic compounds and regulation of genes with consequences for *Spodoptera exigua* oviposition. *Arthropod-Plant Interactions*, 11(4), 591-602. <https://doi.org/10.1007/s11829-017-9503-y>
9. Dyrektywa Parlamentu Europejskiego i Rady 2009/128/WE z dnia 21 października 2009 r. ustanawiająca ramy wspólnotowego działania na rzecz zrównoważonego stosowania pestycydów, art. 14. (2009). Dziennik Urzędowy Unii Europejskiej L 309, 71-86.
10. Farag, M. A., Paré, P. W. (2002). C6-Green leaf volatiles trigger local and systemic VOC emissions in tomato. *Phytochemistry*, 61(5), 545-554. [https://doi.org/10.1016/S0031-9422\(02\)00240-6](https://doi.org/10.1016/S0031-9422(02)00240-6)
11. Gan, Z., Zhou, Q., Zheng, C., Wang, J. (2023). Challenges and applications of volatile organic compounds monitoring technology in plant disease diagnosis. *Biosensors and Bioelectronics*, 237, 115540. <https://doi.org/10.1016/j.bios.2023.115540>
12. Gargiulo, S., Ruocco, M., Loreto, F., Faino, L., Monti, M. M. (2025). Volatile organic compounds in *Solanum lycopersicum* leaves and their roles in plant protection. *Horticulture Research*, 12(10), uhaf181. <https://doi.org/10.1093/hr/uhaf181>
13. Ghosh, S., Didi-Cohen, S., Cna'ani, A., Kontsedalov, S., Lebedev, G., Tzin, V., Ghanim, M. (2022). Comparative analysis of volatiles emitted from tomato and pepper plants in response to infection by two whitefly-transmitted persistent viruses. *Insects*, 13(9), 840. <https://doi.org/10.3390/insects13090840>

14. Gougherty, A. V., Davies, T. J. (2021). Towards a phylogenetic ecology of plant pests and pathogens. *Philosophical Transactions of the Royal Society B*, 376(1837), 20200359. <https://doi.org/10.1098/rstb.2020.0359>
15. Hernández-Aparicio, F., Lisón, P., Rodrigo, I., Bellés, J. M., López-Gresa, M. P. (2021). Signaling in the tomato immunity against fusarium oxysporum. *Molecules*, 26(7), 1818. <https://doi.org/10.3390/molecules26071818>
16. Hunter, J. D. (2007). Matplotlib: A 2D graphics environment. *Computing in Science & Engineering*, 9(3), 90-95. <https://doi.org/10.1109/MCSE.2007.55>
17. Islam, Md. N., Hasanuzzaman, A. T. M., Zhang, Z.-F., Zhang, Y., Liu, T.-X. (2017). High level of nitrogen makes tomato plants releasing less volatiles and attracting more *Bemisia tabaci* (Hemiptera: Aleyrodidae). *Frontiers in Plant Science*, 8. <https://doi.org/10.3389/fpls.2017.00466>
18. Jansen, R. M. C., Miebach, M., Kleist, E., Van Henten, E. J., Wildt, J. (2009). Release of lipoxygenase products and monoterpenes by tomato plants as an indicator of *Botrytis cinerea* -induced stress. *Plant Biology*, 11(6), 859-868. <https://doi.org/10.1111/j.1438-8677.2008.00183.x>
19. Kasal, T. (2015). *Use of biogenic volatile organic compounds to assess the health status of tomato plants (Solanum lycopersicum) cv. "Moneymaker"*. Rozprawa doktorska, Rheinische Friedrich-Wilhelms-Universität Bonn.
20. Kasal-Slavik, T., Eschweiler, J., Kleist, E., Mumm, R., Goldbach, H. E., Schouten, A., Wildt, J. (2017). Early biotic stress detection in tomato (*Solanum lycopersicum*) by BVOC emissions. *Phytochemistry*, 144, 180-188. <https://doi.org/10.1016/j.phytochem.2017.09.006>
21. Kergunteuil, A., Coqueret, V., Larbat, R., Adamowicz, S., Bot, J. L., Robin, C. (2021). Methodological and ecological caveats in deciphering plant volatile emissions: The case study of tomato exposed to herbivory and resource limitation. *Research Square*. <https://doi.org/10.21203/rs.3.rs-419451/v1>
22. Kluyver, T., Ragan-Kelley, B., Pérez, F., Granger, B., Bussonnier, M., Frederic, J., Kelley, K., Hamrick, J., Grout, J., Corlay, S., Ivanov, P., Avila, D., Abdalla, S., Willing, C., Jupyter Development Team. (2016). Jupyter Notebooks – a publishing format for reproducible computational workflows. W: F. Loizides, B. Schmidt (red.), *Positioning and Power in Academic Publishing: Players, Agents and Agendas* (s. 87-90). IOS Press. <https://doi.org/10.3233/978-1-61499-649-1-87>

23. Kutty, N. N., Mishra, M. (2023). Dynamic distress calls: volatile info chemicals induce and regulate defense responses during herbivory. *Frontiers in Plant Science*, 14, 1135000. <https://doi.org/10.3389/fpls.2023.1135000>
24. Lin, P., Paudel, S., Bin Zainuddin, N., Tan, C., Helms, A., Ali, J. G., Felton, G. W. (2022). Low water availability enhances volatile-mediated direct defences but disturbs indirect defences against herbivores. *Journal of Ecology*, 110(11), 2759-2771. <https://doi.org/10.1111/1365-2745.13987>
25. Liu, X., Bowyer, K. W., Hall, L. O. (2004). Decision trees work better than feed-forward back-prop neural nets for a specific class of problems. W: *2004 IEEE International Conference on Systems, Man and Cybernetics (IEEE Cat. No.04CH37583) vol. 6* (s. 5969-5974). IEEE. <https://doi.org/10.1109/ICSMC.2004.1401150>
26. López-Gresa, M. P., Lisón, P., Campos, L., Rodrigo, I., Rambla, J. L., Granell, A., Conejero, V., Bellés, J. M. (2017). A non-targeted metabolomics approach unravels the vocs associated with the tomato immune response against *pseudomonas syringae*. *Frontiers in Plant Science*, 8, 1188. <https://doi.org/10.3389/fpls.2017.01188>
27. Maes, K., Debergh, P. C. (2003). Volatiles emitted from in vitro grown tomato shoots during abiotic and biotic stress. *Plant Cell, Tissue and Organ Culture*, 75(1), 73-78. <https://doi.org/10.1023/A:1024650006740>
28. Martina, M., Tikunov, Y., Portis, E., Bovy, A. G. (2021). The genetic basis of tomato aroma. *Genes*, 12(2), 226. <https://doi.org/10.3390/genes12020226>
29. Meijer, D., Van Der Vleut, J., Weldegergis, B. T., Costaz, T., Duarte, M. V. A., Pekas, A., Van Loon, J. J. A., Dicke, M. (2023). Effects of far-red light on tritrophic interactions between the two-spotted spider mite (*tetranychus urticae*) and the predatory mite *Phytoseiulus persimilis* on tomato. *Pest Management Science*, 79(5), 1820-1828. <https://doi.org/10.1002/ps.7358>
30. Mina, U., Kumar, P., Varshney, C. (2010). Effect of ozone exposure on growth, yield and isoprene emission from tomato (*lycopersicon esculentum* L.) plants. *Journal of Fruit and Ornamental Plant Research*, 72(1), 35-48. <https://doi.org/10.2478/v10032-010-0004-0>
31. Nagalingam, S., Seco, R., Musaev, K., Basu, C., Kim, S., Guenther, A. (2022). Impact of heat stress on foliar biogenic volatile organic compound emission and gene expression in tomato (*solanum lycopersicum*) seedlings. *Elementa: Science of the Anthropocene*, 10(1), 00096. <https://doi.org/10.1525/elementa.2021.00096>

32. Nawrocka, J., Szymczak, K., Maćkowiak, A., Skwarek-Fadecka, M., Małolepsza, U. (2022). Determination of reactive oxygen or nitrogen species and novel volatile organic compounds in the defense responses of tomato plants against *Botrytis cinerea* induced by *Trichoderma virens* trs 106. *Cells*, 11(19), 3051. <https://doi.org/10.3390/cells11193051>
33. Pagadala Damodaram, K. J., Gadad, H. S., Parepally, S. K., Vaddi, S., Ramanana Hunashikatti, L., Bhat, R. M. (2021). Low moisture stress influences plant volatile emissions affecting herbivore interactions in tomato, *Solanum lycopersicum*. *Ecological Entomology*, 46(3), 637-650. <https://doi.org/10.1111/een.13012>
34. Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., Duchesnay, É. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12, 2825-2830.
35. Peñuelas, J., Llusia, J. (2001). The complexity of factors driving volatile organic compound emissions by plants. *Biologia Plantarum*, 44(4), 481-487. <https://doi.org/10.1023/A:1013797129428>
36. Raghava, T., Ravikumar, P., Hegde, R., Kush, A. (2010). Spatial and temporal volatile organic compound response of select tomato cultivars to herbivory and mechanical injury. *Plant Science*, 179(5), 520-526. <https://doi.org/10.1016/j.plantsci.2010.07.020>
37. Silva, D. B., Weldegergis, B. T., Van Loon, J. J. A., Bueno, V. H. P. (2017). Qualitative and quantitative differences in herbivore-induced plant volatile blends from tomato plants infested by either *Tuta absoluta* or *Bemisia tabaci*. *Journal of Chemical Ecology*, 43(1), 53-65. <https://doi.org/10.1007/s10886-016-0807-7>
38. Spanò, R., Mastrochirico, M., Longobardi, F., Cervellieri, S., Lippolis, V., Mascia, T. (2023). Characterization of volatile organic compounds in grafted tomato plants upon potyvirus necrotic infection. *Journal of Integrative Agriculture*, 22(8), 2426-2440. <https://doi.org/10.1016/j.jia.2023.02.032>
39. Sun, Y., Cao, H., Yin, J., Kang, L., Ge, F. (2010). Elevated CO₂ changes the interactions between nematode and tomato genotypes differing in the JA pathway. *Plant, Cell & Environment*, 33(5), 729-739. <https://doi.org/10.1111/j.1365-3040.2009.02098.x>

40. The pandas development team. (2024). *pandas-dev/pandas: Pandas (v2.3.2.)* [Software]. Zenodo. <https://doi.org/10.5281/zenodo.17229934>
41. Tomescu, D., Șumălan, R., Copolovici, L., Copolovici, D. (2017). The influence of soil salinity on volatile organic compounds emission and photosynthetic parameters of *Solanum lycopersicum* L. varieties. *Open Life Sciences*, 12(1), 135-142. <https://doi.org/10.1515/biol-2017-0016>
42. Ustawa z dnia 8 marca 2013 r. o środkach ochrony roślin (Dz.U. z 2013 r. poz. 455).
43. Vehar, A., Maršić, N. K., Železnikar, Š., Potočnik, D., Strojnik, L., Petkovšek, M. M., Šircelj, H., Kastelec, D., Kovačič, A., Pintar, M., Heath, D., Heath, E., Ogrinc, N. (2025). Influence of contaminants of emerging concern on the primary and secondary metabolites of hydroponically grown tomatoes. *Food Chemistry*, 491, 145226. <https://doi.org/10.1016/j.foodchem.2025.145226>
44. Vescio, R., Caridi, R., Laudani, F., Palmeri, V., Zappalà, L., Badiani, M., Sorgonà, A. (2022). Abiotic and herbivory combined stress in tomato: Additive, synergic and antagonistic effects and within-plant phenotypic plasticity. *Life*, 12(11), 1804. <https://doi.org/10.3390/life12111804>
45. Zebelo, S., Piorkowski, J., Disi, J., Fadamiro, H. (2014). Secretions from the ventral eversible gland of Spodoptera exigua caterpillars activate defense-related genes and induce emission of volatile organic compounds in tomato, *Solanum lycopersicum*. *BMC Plant Biology*, 14(1), 140. <https://doi.org/10.1186/1471-2229-14-140>
46. Zhang, J., Zeng, L., Chen, S., Sun, H., Ma, S. (2018). Transcription profile analysis of *Lycopersicum esculentum* leaves, unravels volatile emissions and gene expression under salinity stress. *Plant Physiology and Biochemistry*, 126, 11-21. <https://doi.org/10.1016/j.plaphy.2018.02.016>