

*Miron B. Kursa, Sławomir Walkowiak, Witold R. Rudnicki*

**PRZEWIDYWANIE EWAPOTRANSPIRACJI  
WSKAŹNIKOWEJ W SADZIE NA PODSTAWIE  
NUMERYCZNEJ PROGNOZY POGODY**

***FORECASTING THE POTENTIAL EVAPOTRANSPIRATION  
IN THE ORCHARD WITH THE NUMERICAL WEATHER  
FORECAST***

**Streszczenie**

Numeryczne prognozy pogody osiągnęły już dostateczny poziom dokładności i wiarygodności by w wypadku braku danych pomiarowych traktować przewidywania z modeli jako najlepszą możliwą reprezentację stanu atmosfery w danym miejscu i czasie. W pracy omawiamy zastosowanie modelu numerycznego COAMPS do obliczania i prognozowania ewapotranspiracji wskaźnikowej  $ET_0$ .  $ET_0$  jest obliczana na podstawie danych z modelu, mieszanych danych z modelu i pomiarowych. Zastosowano również metody uczenia maszynowego do poprawy jakości przewidywań modelu. Wyniki wskazują, że w wypadku braku danych pomiarowych zastosowanie danych z numerycznej prognozy daje bardzo dobrą zgodność przewidywanego  $ET_0$  z obliczonym z danych pomiarowych. Modele hybrydowe wykazują nieco większą dokładność od modeli czysto symulacyjnych a zastosowanie uczenia maszynowego pozwala na kolejne podniesienie jakości modelu  $ET_0$ .

**Słowa kluczowe:** Ewaporacja wskaźnikowa, numeryczne prognozy pogody, uczenie maszynowe

***Summary***

*Numerical weather forecasts have reached the accuracy and reliability level that their results can be used as a replacement for the measurements of weather parameters when the availability of the latter is limited. Here we present the application of the COAMPS numerical weather forecast model to prediction of the*

*potential evapotranspiration  $ET_0$ .  $ET_0$  is computed using the data from the model. Also a hybrid model with part of the data coming from the model and part of the data from the measurements was used. Additionally a machine learning methods were used to improve model skill. The results show that application of the simulated data gives very good agreement of the predicted  $ET_0$  with that computed using measurement data. Hybrid models are slightly better than the purely simulation-based and machine learning allows for further improvement of the  $ET_0$  models.*

**Key words:** *Potential evapotranspiration, numerical weather forecast, machine learning*

## WSTĘP

Systematyczne obliczanie ewapotranspiracji wskaźnikowej w trakcie sezonu wegetacyjnego jest podstawą do prowadzenia bilansu wodnego upraw. Zalecana przez FAO formuła Penmana-Monteitha [Penman 1948; Monteith 1965, Allen 1998] opiera się na modelu fizycznym opisującym parowanie i zawiera wielkości, które nie są łatwo mierzalne w praktyce (promieniowanie netto i prędkość wiatru). Dlatego do przybliżonej oceny ewapotranspiracji wskaźnikowej w dłuższej skali czasowej używa się przybliżonych wzorów zawierających jedynie temperaturę i sparametryzowaną promieniowanie – formuła Hargreavsa [Hargreaves 1985, Allen 1998], lub wyłącznie temperaturę.

Mimo coraz szerszego stosowania stacji meteorologicznych do kontroli warunków atmosferycznych stacje zawierające czujniki prędkości wiatru i promieniowania są stosunkowo rzadkie, w porównaniu z prostszymi czujnikami temperatury czy wilgotności powietrza.

Rozwój numerycznych metod prognozowania pogody umożliwia wypełnienie tej luki za pomocą symulowanych wartości wiatru i promieniowania.

Numeryczne prognozy pogody są rutynowo stosowane do przewidywania stanu atmosfery nawet w skali kilkunastodniowej [Newman 2003]. Modele mezoskalowe pozwalają na bardzo dokładne prognozowanie pogody w skali 48-72 godzin na obszarze całego kraju [Jakubiak 2002]. W Interdyscyplinarnym Centrum Modelowania Matematycznego i Komputerowego od 1997 roku w trybie quasi-operacyjnym prowadzone są prace nad prognozowaniem pogody dla obszaru Polski i Europy Środkowej na potrzeby projektów badawczych. Wyniki tych prognoz są udostępniane powszechnie przez stronę WWW (<http://www.meteo.pl/>), gdzie w formie graficznej są prezentowane przebiegi czasowe kluczowych parametrów pogodowych dla wszystkich miejscowości w Polsce.

Kluczowe parametry prognoz są również archiwizowane.

Ze względu na dobrą sprawdzalność prognoz pogody (zwłaszcza krótkoterminowych) można przyjąć, że wartości zmiennych fizycznych opisujących stan atmosfery uzyskane w prognozie pogody są dobrym przybliżeniem rzeczy-

wistego stanu atmosfery. W wypadku, gdy nie dysponujemy wynikami rzeczywistych pomiarów, można przyjąć, że wyniki symulacji są w istocie najlepszym dostępnym oszacowaniem tych wielkości i w wypadku braku wartości zmierzonych doświadczalnie, można użyć tych wartości jako oszacowania wyników pomiaru.

Wyniki numerycznych prognoz pogody mogą być również używane do przewidywania ewapotranspiracji i planowania racjonalnej gospodarki nawodnieniowej.

Przedmiotem niniejszego opracowania jest sprawdzenie dokładności modeli bazujących na prognozie pogody na przykładzie danych uzyskanych dla sadu pomologicznego w Skierniewicach.

## MATERIAŁY I METODY

Zbadano dwa modele ewapotranspiracji, standardowy model Penmana-Monteitha oraz model Hargreavesa, oba według opisu raporcie FAO-56 [Allen 1998].

**Model Penmana-Monteitha.** Model ten bazuje na bilansie energetycznym parowania oraz parametryzacji dyfuzji w zależności od własności pokrywy roślinnej i prędkości wiatru. Ewapotranspiracja wskaźnikowa  $ET_0$  jest w nim opisywana następującym wzorem:

$$ET_0 = \frac{0.408 \Delta (R_n - G) + \gamma \frac{900}{T + 273} u_2 (e_s - e_a)}{\Delta + \gamma (1 + 0.34 u_2)}$$

gdzie

- $ET_0$  jest wyrażona w [mm/dzień lub  $dm^3/m^2/dzień$ ],
- $R_n$  – promieniowanie netto na powierzchni upraw [ $MJ / m^2 / dzień$ ],
- $G$  – strumień ciepła pobieranego przez glebę [ $MJ / m^2 / dzień$ ],
- $T$  – średnia temperatura dzienna, mierzona na wysokości 2m [ $^{\circ}C$ ],
- $u_2$  – prędkość wiatru na wysokości 2 m [ $m / s$ ],
- $e_s$  – ciśnienie parcjale nasyconej pary wodnej [kPa],
- $e_a$  – rzeczywiste ciśnienie parcjale pary wodnej [kPa],
- $(e_s - e_a)$  – deficyt ciśnienia pary wodnej [kPa],
- $D$  – nachylenie krzywej ciśnienia parcjalego pary wodnej [ $kPa / K$ ],
- $\gamma$  – stała psychrometryczna [ $kPa / K$ ].

W modelu P-M zmienne  $R_n$  i  $G$  są to sumy strumieni energii dla 24 godzin. We wzorze występuje również stała 900, która jest wynikiem sumowania strumienia masy. Możliwe jest udoładnienie modelu przez policzenie  $ET_0$  jako

sumy członów godzinnych, z odpowiednio zmodyfikowanymi stałymi we wzorze [3].

**Model Hargreavesa.** Model Hargreavesa jest sparametryzowany dla okresu 24 godzin i nie można go zamienić na wersję obliczaną co godzina. W tym modelu ewapotranspiracja wskaźnikowa  $ET_0$  dana jest jako:

$$ET_0 = 0.0023(T_{mean} + 17.8)\sqrt{T_{max} - T_{min}}R_a$$

gdzie:

$ET_0$  jest wyrażona w [mm/dzień lub  $dm^3/m^2/dzień$ ],

$R_a$  – promieniowanie słoneczne na powierzchni atmosfery [MJ /  $m^2$  / dzień],

$T_{mean}$  – średnia temperatura dzienna, mierzona na wysokości 2m [°C],

$T_{max}$  – maksymalna temperatura dzienna, mierzona na wysokości 2m [°C],

$T_{min}$  – minimalna temperatura dzienna, mierzona na wysokości 2m [°C],

0.0023 – współczynnik empiryczny [°C<sup>-3/2</sup>mm/MJ].

**System numerycznych prognoz pogody w ICM.** W ramach projektu PROZA w sadzie doświadczalnym Instytutu Sadownictwa i Kwiaciarstwa w Skierniewicach została zainstalowana stacja meteorologiczna wyposażona w komplet czujników umożliwiających obliczenie ewapotranspiracji potencjalnej według modelu Penmana-Monteitha. Pomiar temperatury powietrza i wilgotności powietrza, promieniowania oraz prędkości wiatru prowadzone są regularnie. Opracowaniu podlegały dane dla dwóch sezonów wegetacyjnych: pierwszy od 15 kwietnia (data uruchomienia czujników) do 30 września 2009, drugi od 1 kwietnia do 30 września 2010.

W ramach projektu PROZA prowadzone są obliczenia numerycznych prognoz pogody za pomocą modeli UMPL [Davies 2005] i COAMPS [Hodur 1997, Chen 2003]. W bieżącym opracowaniu użyto danych pochodzących z programu COAMPS. Program COAMPS w trybie operacyjnym jest stosowany do prognozowania pogody w horyzoncie trzech dni (72h). Symulacje prowadzone są w oparciu o dane obserwacyjne dostarczane w trybie 12-godzinnym. Dlatego kolejne symulacje przeprowadzane są co 12 godzin, z nominalnym początkiem prognozy o godzinie 0:00 UTC i 12:00 UTC. Nominalny czas prognozy to 84 godziny, jednak opóźnienie pomiędzy akwizycją danych a czasem startu modelu, oraz czas potrzebny na przeprowadzenie obliczeń sprawia, że wyniki modelu z nominalnym czasem startu prognozy o godzinie 0:00 UTC są dostępne około 8:00 UTC. Stan pogody o godzinie H:00 (H<12) w dniu D (D:H:00) jest opisywany przez 8 modeli uruchomionych w czasie D:0:00, D-1:12:00, D-1:0:00, D-2:12:00, D-2:0:00, D-3:12:00, D-3:0:00. Modele te oznaczamy odpowiednio jako Model<sub>0h</sub>, Model<sub>12h</sub>, ..., Model<sub>72h</sub>.

Nieliniowy charakter równań opisujących dynamikę atmosfery sprawia, że wiarygodność prognozy maleje w miarę upływu czasu symulacji. Dlatego jako zamiennik danych pomiarowych powinny być używane wartości z początkowego okresu symulacji. Z drugiej strony asymilacja danych obserwacyjnych wprowadza do modelu pewne nienaturalne zachowania, które zanikają w miarę propagacji modelu. Niemniej jednak z wielu względów praktycznych prognozy nawet obarczone błędem, są wartościową informacją pozwalającą na planowanie prac i zabiegów agrotechnicznych.


Dlatego na potrzeby niniejszego opracowania zbadano jakość prognoz ewapotranspiracji obliczonych na podstawie 3 prognoz dostępnych dla danego dnia (D-1:12:00, D-2:12:00, D-3:12:00), które odpowiadają odpowiednio: najnowszej prognozie dostępnej w danym momencie, prognozie sprzed 24 godzin i prognozie sprzed 48 godzin.

Informacje z pierwszej prognozy mogą być traktowane jako substytut rzeczywistych danych pomiarowych. Z kolei  $ET_0$  pochodzące z dwóch kolejnych prognoz (24- i 48-godzinnej) może posłużyć jako podstawa do planowania nawadniania.

**Modele mieszane.** W wypadku gdy dostępna jest jedynie część danych pomiarowych koniecznych do obliczenia  $ET_0$  w modelu PM można zastosować model mieszany, w którym część danych pochodzi z numerycznej prognozy pogody a część z pomiaru. Dostępność stacji klimatologicznych mierzących wszystkie parametry konieczne dla obliczenia modelu Penmana-Monteitha jest coraz lepsza, jednak w praktyce są one jeszcze rzadkie. Znacznie bardziej rozpowszechnione są stacje o mniejszej funkcjonalności wyposażone jedynie w termometry lub termometry i higrometry. W związku z tym przebadano modele hybrydowe  $ET_0$  w dwóch konfiguracjach najczęściej spotykanych w praktyce, czyli dane z prognozy uzupełnione o mierzoną temperaturę lub o temperaturę i wilgotność powietrza.

**Wykorzystanie metod uczenia maszynowego.** Innym możliwym sposobem poprawienia wyników modelu  $ET_0$  opartych na danych z numerycznej prognozy pogody jest zastosowania modelowania statystycznego lub uczenia maszynowego. W tej pracy użyto statystycznej metody uczenia maszynowego – algorytmu lasu losowego (Random Forest) [Breiman 2001].

Opracowano trzy modele statystyczne. W każdym w nich jako zmiennych niezależnych użyto parametrów pogodowych pochodzących z modelu CO-AMPS. W pierwszym przypadku były to jedyne zmienne modelu. W dwóch kolejnych użyto zmiennych pochodzących z pomiarów, podobnie jak w modelach hybrydowych, z tą różnicą, że w wypadku modeli hybrydowych zmiennych pomiarowych użyto zamiast zmiennych symulowanych, a w wypadku modeli statystycznych zmienne pomiarowe wykorzystano równolegle ze zmiennymi symulacyjnymi.



**Rysunek 1.** Wykres rozrzutu między głównymi modelami. Modele są opisane w formie MODEL-DANE-OKRES, gdzie MODEL  $\in$  {PM (model Penmana-Monteitha), H (model Hargreavesa)}; DANE  $\in$  {Pomiar (dane pomiarowe), Model (dane z prognozy pogody modelu COAMPS)}; OKRES  $\in$  {G (wartości mierzone co godzinę), D (wartości mierzone raz dziennie)}.

**Figure 1.** Scatterplot for main models. Each model is labelled as MODEL-DATA-PERIOD, where MODEL  $\in$  {PM (Penman-Monteith), H (Hargreaves)}; DATA  $\in$  {Pomiar (measurement), Model (data from COAMPS)}; PERIOD  $\in$  {G (hourly values), D (daily averages)}

W drugim modelu jako dodatkowej zmiennej użyto temperatury pochodzącej z pomiarów, a w trzecim temperatury i wilgotności względnej pochodzącej z pomiarów.

## WYNIKI

Wszystkie modele ewapotranspiracji potencjalnej, zarówno oparte o dane pomiarowe jak i te oparte o dane z numerycznej prognozy pogody są wysoce skorelowane. Na rysunku 1 pokazano wykresy rozrzutu między głównymi modelami. Punktem odniesienia do wszystkich innych wyników jest ewapotranspiracja potencjalna wyliczana z danych pomiarowych uśrednianych w skali godzinowej.

Można zauważyć, że wartości mierzone w odstępach godzinnych i dobowych są ze sobą dobrze skorelowane. Wizualnie korelacja między wartościami policzonymi według modelu Penmana-Monteitha (PM) uzyskanymi z obserwacji i z prognozy pogody jest wyższa niż korelacja pomiędzy modelem PM a modelem Hargreavesa. To spostrzeżenie potwierdza dokładniejsza analiza danych liczbowych zaprezentowana w tablicy 1. Model pochodzący z danych pomiarowych uśrednianych co 24 godziny jest bardzo bliski do referencyjnego najdokładniejszego modelu godzinowego. Co ciekawe, model dobowy, mimo bardzo wysokiej korelacji z modelem godzinowym, w sposób systematyczny zawyża nieco wartości  $ET_0$ , co wynika z nieliniowego przebiegu współczynników  $D$  i  $\gamma$  w modelu.

**Tabela 1.** Porównanie z modelem referencyjnym  $ET_0$  dla wybranych modeli. Oznaczenia PM – model Penmana-Monteitha, Harg. – model Hargreavesa, COAMPS+XXh – model uzyskany z danych pochodzących z prognozy pogody z wyprzedzeniem XX godzin. Kolumny 2-4 zawierają dane uśrednione dla dni, kolumny 5-7 uśrednione tygodniowo. Kolumna 8 zawiera średnie dzienne odchylenie uśrednione po tygodniu


**Table 1.** Comparisons with reference  $ET_0$  for selected models. Row heads:

PM – Penman-Monteith model, Harg. – Hargreaves model, COAMPS+XXh – model based on forecast (XX hours in advance). Columns 2-4 display daily averages, columns 5-7 weekly averages. Column 8 holds weekly averaged RMS per day

Model	dienne			sumy tygodniowe			
	r	r <sup>2</sup>	RMS	r	r <sup>2</sup>	RMS	RMS/ dzień
1.	2.	3.	4.	5.	6.	7.	8.
PM-h	100%	100%	0,00	100%	100%	0,00	0,00
PM-d	98%	97%	0,39	99%	99%	1,98	0,28
PM-h COAMPS	89%	80%	0,79	95%	91%	2,54	0,36
PM-h COAMPS +24h	83%	69%	0,88	88%	77%	1,45	0,21
PM-h COAMPS +48h	75%	57%	1,04	86%	74%	1,35	0,19
PM-d COAMPS	89%	79%	1,01	95%	90%	5,03	0,72
PM-d COAMPS +24h	83%	68%	0,99	89%	78%	3,39	0,48
PM-d COAMPS +48h	75%	56%	1,11	86%	74%	2,98	0,43
Harg.	84%	71%	5,92	87%	76%	38,9	5,56
Harg. COAMPS	78%	61%	5,70	92%	84%	37,7	5,38
Harg. COAMPS +24h	74%	55%	5,40	92%	84%	35,3	5,04
Harg. COAMPS +48h	70%	48%	5,32	77%	60%	34,5	4,92

Model PM-h COAMPS i model PM-d COAMPS mają podobną korelację z modelem referencyjnym, wynoszącą 89%, a zatem model prognostyczny wyjaśnia około 80% zmienności w modelu referencyjnym. Podobnie jak model PM-d, model PM-d COAMPS nieco zawyża wynik w stosunku do modelu referencyjnego.

W praktyce interesujące jest na ile można zaufać opartej na modelu COAMPS prognozie  $ET_0$  na kolejne 24 lub 48 godzin. Jak można przewidzieć jakość modelu  $ET_0$  pogarsza się z wiekiem prognozy. O ile korelacja dla modelu opartego na danych najnowszych wynosi 89% to dla modelu 24-godzinnego wynosi 83% a dla 48-godzinnego 75%. Co ciekawe, systematyczne odchylenie od modelu referencyjnego jest najmniejsze dla  $ET_0$  wyliczonej z modelu 48-godzinnego (rys. 2.)



**Rysunek 2.** Wykres pudełkowy rozkład odchyleń od modelu referencyjnego  $ET_0$  dla modeli PM obliczonych w oparciu o różne dane. P – model referencyjny, M12 – model prognostyczny bieżący, M36 – model prognostyczny +24h, M60 – model prognostyczny +48h. Pudełka puste reprezentują modele godzinowe a pudełka zaciemnione modele dobowe. Wartości zaznaczone jako okręgi odbiegają od mediany o więcej niż 1.5 raza niż odległość między 25 a 75 percentylem

**Figure 2.** Boxplot for deviations from the reference  $ET_0$  for PM models computed from various data. P – reference model, M12 – model based on current forecast, M36 – model based on 24 hours forecast, M60 – model based on 48 hours forecast. Empty and filled boxes correspond to hourly and daily models, respectively. The hollow circles correspond to values that deviate from median more than 1.5 times the distance between 25th and 75th percentile



Wyniki wszystkich wariantów modelu Hargreavesa są zdecydowanie gorsze niż wyniki modelu PM opartego na danych prognostycznych. Współczynnik korelacji modelu Hargreavesa opartego na danych pomiarowych z modelem referencyjnym wynosi 84% a co za tym idzie ten model wyjaśnia około 70% zmienności w referencyjnym modelu  $ET_0$ . Co gorsza model Hargreavesa w sposób systematyczny podaje drastycznie zawyżone wartości  $ET_0$  – o około 5mm słupa wody dziennie. Wady modelu opartego na danych pomiarowych są powielane przez model oparty na danych pochodzących z prognozy pogody. Powyższe wyniki wskazują jednoznacznie, że w sytuacji dostępu do wyników numerycznych prognoz pogody używanie modelu Hargreavesa do obliczania ewapotranspiracji potencjalnej nie ma racji bytu.

Przebadano dwie konfiguracje modeli mieszanych w których czyli dane z prognozy uzupełnione o mierzoną temperaturę lub o temperaturę i wilgotność powietrza. Skorygowane przy pomocy lasu losowego modele  $ET_0$  opracowano dla wszystkich wariantów modelu opartego na danych prognostycznych i hybrydowych. Podsumowanie wyników dla wszystkich poprawionych modeli zaprezentowano w tabeli 2.

**Tabela 2.** Porównanie z modelem referencyjnym  $ET_0$  dla różnych wariantów modelu PM opartego na danych z modelu COAMPS. Kolumny 2-4 zawierają dane uśrednione dla dni, kolumny 5-7 uśrednione tygodniowo. Kolumna 8 zawiera średnie dzienne odchylenie uśrednione po tygodniu. W wierszach: COAMPS (+XXh) – dane wyłącznie z modelu COAMPS (z wyprzedzeniem XX godzin); + temp. – temperatura z pomiarów; +wilg. – wilgotność z pomiarów; RF – model został poprawiony przy użyciu uczenia maszynowego metodą lasu losowego

**Table 2.** Comparisons with reference  $ET_0$  for various variants of PM model based on COAMPS. Row heads: COAMPS+XXh – pure prognostic data (XX hours in advance); +temp – measured temperature, +wilg – measured humidity; RF – random forest model.


Columns 2-4 display daily averages, columns 5-7 weekly averages. Column 8 holds weekly averaged RMS per day

Model	dzienne			sumy tygodniowe			
	r	r <sup>2</sup>	RMS	r	r <sup>2</sup>	RMS	RMS/ dzień
1.	2.	3.	4.	5.	6.	7.	8.
COAMPS	89%	80%	0,79	95%	91%	2,54	0,36
COAMPS + temp.	91%	83%	0,74	96%	92%	2,60	0,37
COAMPS + temp. + wilg.	93%	87%	0,74	96%	91%	3,33	0,48
RF COAMPS	91%	83%	0,64	97%	93%	0,67	0,10
RF COAMPS + temp.	94%	87%	0,55	98%	95%	0,58	0,08
RF COAMPS + temp. + wilg.	96%	91%	0,46	98%	96%	0,53	0,08
COAMPS +24h	83%	69%	0,88	88%	77%	1,45	0,21
RF COAMPS +24h	86%	73%	0,79	93%	86%	0,99	0,14
COAMPS +48h	75%	57%	1,04	86%	74%	1,35	0,19
RF COAMPS +48h	79%	62%	0,95	88%	77%	1,30	0,19

Uzupełnienie danych o dane doświadczalne poprawia znacząco korelację modelu z modelem referencyjnym, nie ma natomiast znaczącej poprawy jeśli chodzi o błąd średniokwadratowy. Z kolei zastosowanie metod uczenia maszynowego skutkuje zarówno poprawą korelacji jak i zmniejszeniem błędu średniokwadratowego, przy czym ten drugi efekt jest najbardziej widoczny jest w wynikach kumulowanych w ciągu tygodnia.

Najlepsze efekty uzyskano przy zastosowaniu metod uczenia maszynowego do modeli hybrydowych. Model  $ET_0$  uzyskany metodami uczenia maszynowego z wykorzystaniem danych pomiarowych dla temperatury i wilgotności uzyskał korelację z modelem referencyjnym na poziomie 96% (98% dla kumulacji tygodniowej) i średniokwadratowy błąd na poziomie 0,46mm słupa wody (0,53 mm dla kumulacji tygodniowej).

Wyniki trzech modeli  $ET_0$  skumulowane dla sezonów wegetacyjnych 2009 i 2010 zaprezentowano na rys. 3. Widać dobrą zgodność modelu PM opartego o dane pogodowe z modelem PM obliczanym w oparciu o dane pomiarowe. Modele  $ET_0$  uzyskane metodami uczenia maszynowego niemal doskonale odwzorowują  $ET_0$  z danych pomiarowych. Wyniki modeli hybrydowych nie są na tym wykresie pokazane ponieważ są nieodróżnialne od modelu PM-Model-G; podobnie nie są pokazane wyniki dla modeli uzyskanych metodą lasu losowego z modeli hybrydowych, które są nierozróżnialne od wyników modelu RF-G.



**Rysunek 3.** Skumulowane wartości  $ET_0$  w modelu PM z trzech modeli dla sezonów wegetacyjnych 2009 (lewy panel) i 2010 (prawy panel). Oznaczenia: PM-Pomiar-G model referencyjny Penmana-Monteitha liczony z rozdzielczością godzinową, PM-Model-G model PM oparty wyłącznie na danych z modelu numerycznego COAMPS, RF-G model uzyskany metodą lasu losowego w oparciu o dane z modelu numerycznego

**Figure 3.** Cumulated  $ET_0$  in PM model from three variants for 2009 (left) and 2010 (right) growing seasons. PM-Pomiar-G – the reference hourly Penman-Monteith model, PM-Model-G the PM model based entirely on COAMPS data, RF-G the Random Forest predictions based on numerical model

## PODSUMOWANIE

Zastosowanie wyników numerycznych modeli prognoz pogody do przewidywania ewapotranspiracji wskaźnikowej daje bardzo dobre wyniki w wypadku gdy nie są dostępne dane pomiarowe. Modele hybrydowe wykorzystujące częściowo dane pomiarowe (temperatura lub temperatura i wilgotność powietrza) a częściowo symulowane (pozostałe zmienne w równaniu PM) wykazują nieco wyższą korelację z modelem referencyjnym, jednak sumaryczny błąd jest podobny jak w modelu czysto symulacyjnym. Z kolei zastosowanie metod uczenia maszynowego do opracowania modelu empirycznego umożliwia poprawienie zarówno korelacji jak i błędu całkowitego.

Taki rezultat jest możliwy, ponieważ algorytm uczenia maszynowego jest w stanie z różnic między obserwowanymi a rzeczywistymi wartościami temperatury opracować poprawkę dla zmiennych nieobserwowanych (promieniowania i wilgotności powietrza). Wyniki te zostały otrzymane dla jednej stacji pomiarowej i jest kwestią otwartą czy model statystyczny otrzymany metodą uczenia maszynowego na danych z jednej stacji ma zastosowania dla innych stacji pomiarowych zlokalizowanych w podobnych lub innych warunkach.

Wyniki uzyskane w tym opracowaniu będą poddane weryfikacji eksperymentalnej w dalszej części projektu PROZA.

*Badania opisane w tym opracowaniu były prowadzone w ramach projektu PROZA finansowanego z funduszy strukturalnych Unii Europejskiej, grant numer UDA-POIG.01.03.01-00-140/08-00. Dane eksperymentalne otrzymano od współpracującego z nami zespołu prof. W. Tredera z Instytutu Sadownictwa i Kwiaciarstwa w Skierniewicach.*

## BIBLIOGRAFIA

- Penman, H.L. *Natural evaporation from open water, bare soil and grass*. Proc. Roy. Soc. London A 194, (1948), 120-145 s.
- Allen, R.G.; Pereira, L.S.; Raes, D.; Smith, M. *Crop Evapotranspiration—Guidelines for Computing Crop Water Requirements*. FAO Irrigation and drainage paper 56. FAO Rome, Italy, (1998). 300ss.
- Breiman, L. *Random Forests*. Machine Learning 45, (2001), 5-32s.
- Chen, S., Cummings, J. A., Doyle, J. D., Hodur, R. M., Holt, T. R., Liou, C. S., Liu, M., Mirin, A., Ridout, J. A., Schmidt, J. M., Sugiyama, G., and Thompson, W. T. *COAMPS Version 3 model description*. NRL/PU/7500-03-448. Naval Research Laboratory, Monterey, CA, (2003), 143ss.
- Davies, T., Cullen, M. J. P., Malcolm, A. J., Mawson, M. H., Staniforth, A., White A. and Wood, N *A new dynamical core for the Met Office's global and regional modelling of the atmosphere*. Q. J. R. Meteorol. Soc. 131, (2005), 1759–1782s.
- Hargreaves, G.H. and Samani, Z.A. *Reference crop evapotranspiration from temperature*. Transaction of the ASAE 28, (1985), 96-99s.

- Hodur, R. M., *The Naval Research Laboratory's Coupled Ocean/Atmosphere Mesoscale Prediction System (COAMPS)*. Mon. Wea. Rev. 125, (1997), 1414-1430s.
- Jakubiak, B. (ed.). *Research Works based on the ICM's UMPL numerical weather prediction system results*. Wydawnictwa ICM, Warszawa, (2002), 156ss.
- Monteith, J.L. *Evaporation and environment*. Symp. Soc. Exp. Biol. 19, (1965), 205-224s.
- Newman, M., Sardeshmukh, P.D., Winkler, C.R., Whitaker, J.S. *A Study of Subseasonal Predictability*. Mon. Wea. Rev., 131, 2003, 1715–1732s.

Miron B. Kursa  
e-mail: M.Kursa@icm.edu.pl  
Mgr Sławomir Walkowiak  
e-mail: S.Walkowiak@icm.edu.pl  
Dr Witold R. Rudnicki  
e-mail: W.Rudnicki@icm.edu.pl  
Interdyscyplinarne Centrum Modelowania Matematycznego i Komputerowego  
Uniwersytet Warszawski  
Pawińskiego 5A, 02-106 Warszawa

Recenzent: *Prof. dr hab. Leszek Łabędzki*