Sveučilište u Zagrebu Agronomski fakultet
Svetošimunska cesta 25, 10000 Zagreb
Telefon: +385 (0)1 2393 777
E-mail: dekanat@agr.hr
Web: www.agr.unizg.hr

Epidemiologija biljnih bolesti (78534)

Nositelj kolegija

prof. dr. sc. Snježana Topolovec-Pintarić

Opis kolegija

Modul donosi znanja o važnosti epidemiologije i pravodobne prognoze pojave bolesti kao osnove suvremene zaštite bilja. Uvodna predavanja obrađuju temeljne spoznaje epidemiologije i ekologije bolesti kao preduvjete za osmišljavanje i izradu prognostičkog modela. Naredna predavanja posvećena su savladavanju osnovnih principa najčešće primjenjivanih modela prognozne i signalizacije pojave ekonomski značajnih biljnih bolesti. Zasebna programska jedinica posvećena je upoznavanju s organizacijom i metodikom rada prognoznih službi.

ECTS: **3.00**

Engleski jezik: **R1**

E-učenje: **R1**

Sati nastave: 30
Predavanja: 22
Auditorne vježbe: 8

Izvođač predavanja

- prof. dr. sc. Snježana Topolovec-Pintarić
- prof. dr. sc. Edyta Đermić

Izvođač vježbi

- prof. dr. sc. Snježana Topolovec-Pintarić
- prof. dr. sc. Edyta Đermić

Izvođač seminara

- prof. dr. sc. Darko Vončina

Ocjenjivanje

Dovoljan (2): 60-70%
Dobar (3): 71-80%
Vrlo dobar (4): 81-90%
Izvrstan (5): 91-100%

Uvjeti za dobivanje potpisa

Odslušana predavanja i vježbe.
Izrada seminara.

Vrsta kolegija

- Diplomski studij / Fitomedicina (Izborni kolegij, 2. semestar, 1. godina)

Developed by Superfluo d.o.o. • www.superfluo.hr

Sveučilište u Zagrebu Agronomski fakultet
Svetošimunska cesta 25, 10000 Zagreb
Telefon: +385 (0)1 2393 777
E-mail: dekanat@agr.hr
Web: www.agr.unizg.hr

Opće kompetencije

Stjecanje znanja i kompetencija koje nalaze primjenu u radu poljoprivrednih savjetodavnih službi. Studenti koji svoju budućnost vide u ulozi poljoprivrednog proizvođača moći će steći vještinu prognoziranja pojave bolesti i pravovremenog provođenja zaštitnih mjera.

Oblici nastave

- Predavanja
- Auditorne vježbe
- Seminari

Ishodi učenja i način provjere

Ishod učenja	Način provjere
objasniti značaj nauke o nastanku i širenju biljnih bolesti	
nabrojati aktualne prognostičke modele	
identificirati osnovne komponente prognostičkog modela	
opisati pojedine prognostičke modele	
izračunati pojavnost plamenjače vinove loze temeljem Můllerove krivulje	
zaključiti i opasnosti izbijanja epifitocije bakterijskog paleža voćaka	
razlikovati i izračunati: procjenu napada bolesti, jačinu napada bolesti, visinu gubitka uroda	
razlikovati tipove epifitocija	
objasniti organizaciju prognoznih službi u RH	

Developed by Superfluo d.o.o. • www.superfluo.hr

Sveučilište u Zagrebu Agronomski fakultet
Svetošimunska cesta 25, 10000 Zagreb
Telefon: +385 (0)1 2393 777
E-mail: dekanat@agr.hr
Web: www.agr.unizg.hr

Način rada

Obveze nastavnika

U skladu sa programskim sadržajem predmeta nastavnici su obavezni omogućiti polaznicima stjecanje osnovnog znanja iz fitopatoloških struka mikologije, bakteriologije i virologije. Teoretsko znanje transferirat će putem učioničke nastave obogaćene informacijsko-komunikacijskom tehnologijom (e-kolegij u sustavu Merlin) za koje nastavnici trebaju osigurati potrebne nastavne materijale (skripta, vježbenica). U sklopu auditornih vježbi nastavnik treba studentima prenijeti i razvijati vještine rada u postojećim prognostičkim modelima. Tijekom nastavnog procesa nastavnik će kroz konzultativni rad primjenom komunikacijske tehnologije osiguravati podršku studentima tijekom usvajanja gradiva i ponavljanja. Usvojeno znanje nastavnik se obvezuje tijekom trajanja nastave evaluirati formativnom procjenom. Sumativnom procjenu znanja nastavnik je obvezan provesti kroz evaluaciju rada vježbenog djela tijekom semestra te završnim testom u ispitnom roku.

Obveze studenta

Od studenata se očekuje interaktivno sudjelovanje u nastavnom procesu koje podrazumijeva: redovito pohađanje učioničke nastave, samostalna predpriprema za istu kod kuće putem materijala dostupnih na e-kolegiju, sudjelovanje na forumima e-kolegija, a sve u cilju uspješnog usvajanja znanja. Studenti su dužni pristupiti nekom od ponuđenih oblika sumativne provjere usvojenog znanja.

Polaganje ispita

Elementi praćenja	Maksimalno bodova ili udio u ocjeni	Bodovna skala ocjena	Ocjena	Broj sati izravne nastave	Ukupni broj sati rada prosječnog studenta	ECTS bodovi
Interaktivnost u učioničkoj nastavi te aktivnost u pregledu i korištenju nastavnih materijala u e-učenju.	25 %	F; FX, E D; C B A	Nedovoljan (1) Dovoljan (2) Dobar (3) Vrlo dobar (4) Izvrstan (5)	P 22	13,5	0,45
Aktivnost u radu s prognostičkim modelima.	60 %	F - neuspješan; FX - nedovoljan E - dovoljan D - zadovoljavajući; C - dobar B - vrlo dobar A - izvrstan	Nedovoljan (1) Dovoljan (2) Dobar (3) Vrlo dobar (4) Izvrstan (5)	AV 8	60	2
Vježbe	10 %	F; FX E D;C B A	Nedovoljan (1) Dovoljan (2) Dobar (3) Vrlo dobar (4) Izvrstan (5)	AV 8	15	0,5

Developed by Superfluo d.o.o. • www.superfluo.hr

Sveučilište u Zagrebu Agronomski fakultet
Svetošimunska cesta 25, 10000 Zagreb
Telefon: +385 (0)1 2393 777
E-mail: dekanat@agr.hr
Web: www.agr.unizg.hr

Elementi praćenja	Maksimalno bodova ili udio u ocjeni	Bodovna skala ocjena	Ocjena	Broj sati izravne nastave	Ukupni broj sati rada prosječnog studenta	ECTS bodovi
Ispit	5 %	0-59 60-69 70-79 80-89 90-100	Nedovoljan (1) Dovoljan (2) Dobar (3) Vrlo dobar (4) Izvrstan (5)		1,5	0,05
Ukupno	100 %	(3) Uspjeh studenata prema ECTS sustavu bodova izražava se slovima od F do A, kako slijedi: F (neuspješan), FX (nedovoljan), E (dovoljan), D (zadovoljavajući), C (dobar), B (vrlo dobar), A (izvrstan)	Ocjene od 1 do 5, kako slijedi: 1 (nedovoljan), 2 (dovoljan), 3 (dobar), 4 (vrlo dobar), 5 (izvrstan).	P 22; AV 8	90	3

Elementi praćenja	Opis	Rok	Nadoknada
Interaktivnost u učioničkoj nastavi te aktivnost u pregledu i korištenju nastavnih materijala u e-učenju.	Predavanja su organizirana po ERR okviru kako bi promovirala interaktivnost studenata i poticala kritičko razmišljanje.		
Aktivnost u radu s prognostičkim modelima.	Upoznavanje prognostičkih modela kroz rješavanje zadataka pomoću matematičkih formula na kojima se model temelji. Kompjutorski modeli se praktično uvježbavaju kroz simulaciju prognoze.		
Vježbe	Auditorne vježbe upoznaju studenta sa teoretskom osnovom prognostičkih modela.		
Ispit	Pismeno ili usmena provjera znanja	Redovni ispitni termini tijekom ispitnih rokova.	Sukladno Pravilniku o studiranju 4. izlazak na ispit održat će se pred povjerenstvom. U slučaju pada na ispitu pred povjerenstvom student ponovno upisuje predmet.

Developed by Superfluo d.o.o. • www.superfluo.hr

Sveučilište u Zagrebu Agronomski fakultet
Svetošimunska cesta 25, 10000 Zagreb
Telefon: +385 (0)1 2393 777
E-mail: dekanat@agr.hr
Web: www.agr.unizg.hr

Tjedni plan nastave

1. Epidemiologija biljnih bolesti: P- Uvodu epidemiologiju biljnih bolesti. Proces patogeneze. Osnovni model životnog ciklusa gljiva i pseudo gljiva: održavanje u nepovoljnim uvjetima, primarne infekcije, sekundarne infekcije.
2. Epidemiologija biljnih bolesti: P - Inicijalni inokulum patogena i numerički prag infekcije. Preduvjeti za nastanak i razvoj epifitocije.
3. Epidemiologija biljnih bolesti: P - Patogeneza bakterioza i viroza.. Izvori inokuluma za bakterijske zaraze. Izvori primarnih zaraza biljnim virusima
4. Epidemiologija biljnih bolesti: P - Preduvjeti za nastanak i razvoj bakterijskih i viralnih epifitocija.
5. Ekologija biljnih bolesti: P - Ekološki čimbenici značajni za razvoj bolesti. Abiotske i biotske biljne bolesti..
6. Ekologija biljnih bolesti: P - Klimatske mjerne stanice
7. Modeli prognoze značajnih biljnih bolesti: P - Blitecast model za prognozu krumpirove plijesni, Müllerov model prognoze plamenjače vinove loze.
8. Modeli prognoze značajnih biljnih bolesti: P - Millsova metoda prognoze fuzikladija.
9. Modeli prognoze značajnih biljnih bolesti: P -. Botman model za prognozu sive plijesni
10. Modeli prognoze značajnih biljnih bolesti: P – Aktualni modeli prognoze značajnih biljnih bakterioza
11. Modeli prognoze značajnih biljnih bolesti: P - Monitoring dinamike razvoja i varijabilnosti populacija ekonomski značajnih bakterijskih i viralnih epifitocija i njegova informatizacija
12. Prognozna služba: V (A) -Organizacija i metodika rada.
13. Prognoza plamenjače vinove loze: V (A) - Samostalna izrada zadatka
14. Prognoza bakterijske paleži: V (A) - Samostalna izrada zadatka
15. Završni ispit (pismenii)

Obvezna literatura

1. Cambel, C. L., Madden, L.V., (1990). Introduction to Plant Disease Epidemiology. N.Y.: Wiley.
2. Brown, J. F., Ogle, H. J. ed.(1997). Plant pathogens and Plant diseases. APPS. Armidale, N.S.W.: University of New England.
3. Đermić, E. (2002). Identifikacija, prognoza i suzbijanje bakterijske paleži jabuka (Erwinia amylovora (Burrill) Winslow et al.) u Hrvatskoj. (mag. rad. Sveučilište u Zagrebu, Agronomski fakultet). Zagreb: vlast. nakl.
4. IOBC/WPRS Bulletins

Preporučena literatura

1. Internet stranice Ministarstva poljoprivrede, ribarstva i ruralnog razvitka
2. Internet stranice HZPSS
3. Persley, J. G. (1999). Biotechnology and Integrated Pest Management. Wallingford: CABI.
4. Schots, A., Dewey, F. M., Dewey,O. R. (1994). Modern assays for plant pathogenic fungi: indetification, detection, and quantification (odabrana poglavlja). Wallingford: CABI
5. Kiraly, Z., Klkement, Z.(1974). Methods in Plant Pathology. Budapest: Akademiai Kiado.

Developed by Superfluo d.o.o. • www.superfluo.hr