Ausführlicher Bericht / Eingehende Darstellung

Teil II des Schlussberichts – Universität Freiburg (UFR), AG Fleck

Verbundprojekt FreshTwin · FKZ 16IS22048D · Laufzeit 01.12.2022 – 30.09.2025 (nach kostenneutraler Verlängerung um 4 Monate)

1. Ausgangspunkt für die Universität Freiburg und Zielsetzung

Die Universität Freiburg (UFR, AG Fleck) war von Projektbeginn an (01.12.2022) Teil des FreshTwin-Konsortiums und über die gesamte – um vier Monate auf 34 Monate verlängerte – Laufzeit (bis 30.09.2025) beteiligt. FreshTwin verfolgte das Ziel, mittels innovativer Messmethoden (VIS/NIR- und Hyperspektralspektroskopie) und spezialisierter KI-Modelle die Bestimmung und Prognose der Qualitätseigenschaften frischer Lebensmittel zu verbessern und teilweise zu automatisieren, um Produzenten und Händlern bessere, datenbasierte Entscheidungen in Logistik und Warenannahme zu ermöglichen und Verluste durch vorzeitig verdorbene Ware zu reduzieren.

Der Beitrag der UFR bestand in der Entwicklung hybrider Grey-Box-Modelle, die mechanistische (struktur-/differentialgleichungsbasierte) Modelle mit Methoden des maschinellen Lernens kombinieren – ein Ansatz, der im Gegensatz zu reinen Black-Box-Modellen erklärbar bleibt (Explainable AI) und auch mit kleineren bzw. unsichereren Referenzdatensätzen verlässliche Aussagen ermöglichen soll. UFR war für zwei Projektziele verantwortlich: PZ5 (Dokumentation der Methoden zur Bestimmung von Qualitätsattributen, fällig M5) und PZ7 (Nachweis, dass Grey-Box-Modelle auch mit kleineren Referenzdatensätzen verlässliche Ergebnisse liefern, fällig M18). Zusätzlich übernahm UFR die Leitung der Arbeitspakete AP1.2 (Erhebung der Referenz-/Trainingsdatensätze), AP2.2 (Entwicklung der hybriden Grey-Box-Modelle / Digitaler Zwilling) und AP3.2 (Demonstratoren) und beteiligte sich an AP1.1, AP1.3, AP2.1, AP2.3 sowie AP4.1–4.5.

2. Durchgeführte Arbeiten

AP1.1 – Anforderungsanalyse und Vorarbeiten

Die Anforderungsanalyse, Literaturrecherche und Vorversuche wurden durchgeführt. Als Referenzprodukte wurden Trauben und Äpfel (später konkret die Sorten Braeburn und Elstar) ausgewählt.

AP1.2 – Erhebung der Referenz-/Trainingsdatensätze (UFR-Leitung)

Für Trauben wurden Süße, Säuregehalt und Trockenmasse einzelner Früchte unterschiedlicher Kultivare gemessen; die Trauben wurden bei verschiedenen Temperaturen über 14 Tage in regelmäßigen Abständen vermessen, zusätzlich mit dem VIS/NIR-Spektrometer von TSN sowie photographisch (eigens gebaute Fotobox unter konstanten Lichtbedingungen) und hyperspektral (CUB-Kamera, deren Fotobox wegen Wärmeentwicklung um ein Ventilationssystem erweitert wurde). Es entstand ein Datensatz von über 800 Einzelmessungen.

Abb. 1: Eigens gebaute Fotobox mit aufgesetzter Kamera und definierter Beleuchtung für die photographische Vermessung unter konstanten Lichtbedingungen.

Abb. 2: Nachträglich ergänztes Ventilationssystem der Fotobox für die hyperspektrale Kamera (CUB), notwendig wegen der Wärmeentwicklung während des Betriebs.

Für Äpfel (Braeburn, Elstar) wurde 2024 – mit zusätzlicher Unterstützung studentischer Hilfskräfte – ein umfangreicher Datensatz von über 800 Früchten erhoben: Süße (Brix), Säure (titrierbare Säure), Festigkeit und Trockenmasse, jeweils mit mehrfacher spektraler

Vermessung an mindestens zwei Stellen je Frucht (zur Quantifizierung der Streuung durch menschliche Handhabung). Zusätzlich wurden induzierte Druckstellen über drei Wochen bei Raumtemperatur in ihrer Entwicklung dokumentiert; die beobachtete Streuung war erheblich (von deutlich sichtbarer Fäulnis bis zu folgenloser Eindellung).

AP1.2/AP1.3 – Chemometrische Modelle und Bilderkennung

Aus den Traubendaten wurden chemometrische Modelle zur Schätzung von Trockenmasse und Süße entwickelt, trainiert und validiert; sie erreichen eine zufriedenstellende Vorhersagegüte ($r^2 \geq 0{,}8$). Die Schätzung der Gesamtsäure ist noch nicht ausreichend genau ($r^2 = 0{,}5$); hierzu wurden gemeinsam mit TSN intensive Experimente zur Verbesserung des Signal-Rausch-Verhältnisses des VIS/NIR-Spektrometers durchgeführt. Zur automatischen Erkennung und Segmentierung der Trauben aus Bildern wurden im Labor erzeugte Bilder annotiert und neuronale Netze trainiert. Gemeinsam mit TSN wurde zudem ein pixelbasierter Verbräunungsindex entwickelt, der Aussagen über das optische Erscheinungsbild der Trauben während der Lagerung erlaubt, sowie ein Modul zur Bewertung des Qualitätszustands von Trauben anhand von RGB-Bildern.

AP2.2 – Hybride Grey-Box-Modelle / Digitaler Zwilling (UFR-Leitung)

Es wurde ein Konzept für einen lernenden Digitalen Zwilling entwickelt, das auf hybriden Grey-Box-Modellen basiert: KI-Module zur Zustandserfassung (VIS/NIR-Spektroskopie, Hyperspektral- und RGB-Bilder) wurden mit dynamischen Modellen für die Qualitätsparameter (z. B. Wasserverlust während der Lagerung, kalibriert anhand der AP1.2-Daten) und Konzepten des Bayes'schen maschinellen Lernens zusammengeführt. Durch den hybriden Ansatz bleiben die Aussagen des Digitalen Zwillings stets erklärbar (Explainable AI). Das Konzept wurde für Trauben implementiert und in der Cloud-Umgebung von TSN getestet: Der Zwilling umfasst Segmentierung/Erkennung der Trauben, Erfassung des Farbzustands, Prozessierung des VIS/NIR-Spektrums, Vorhersage von Trockenmasse und Süße, Zustandsschätzung der Liefereinheit sowie die Berechnung zukünftiger Zustände unter wählbaren Lagerszenarien; bei mehreren Messungen entlang der Lieferkette gleicht der Zwilling frühere Prognosen mit neuen Messungen ab und verbessert dadurch iterativ seine Vorhersagegüte („lernender" Zwilling).

Für Äpfel zeigte sich, dass die übliche manuelle Festigkeitsmessung mit dem Handpenetrometer (Wareneingangspraxis) sehr ungenau und destruktiv ist und stark von der Andruckgeschwindigkeit abhängt – damit erzeugte Trainingsdaten wären stark verrauscht. UFR entschied sich daher für einen hybriden Ansatz: Mit einem automatischen Kraft-Weg-Messgerät (definierte Geschwindigkeit) wurden die Kraft-Weg-Kurven unter reproduzierbaren Bedingungen erfasst und mittels eines visko-elastischen physikalischen Modells (Maxwell-Kelvin-Voigt-Element, drei Parameter) gefittet. Das einfache Modell beschreibt die grobe Struktur der Kurven gut (höherfrequente Schwingungsanteile bleiben unberücksichtigt; aufwendigere Modellansätze wurden getestet, aber aus Effizienzgründen nicht weiterverfolgt). Die Fitparameter wurden per maschinellem Lernen mit den VIS/NIR-Spektren von TSN korreliert ($r^2 = 0{,}4$) – ein vor dem Hintergrund der groben, destruktiven Referenzmessung bemerkenswertes Ergebnis und ein direkter Beleg für PZ7 (robuste Aussagen trotz unsicherer/kleinerer Referenzdaten).

$$\sigma(x) = \mu_1 - \mu_1 e^{-\alpha x}\left(\frac{\alpha}{\omega}\sin(\omega x) + \cos(\omega x)\right)$$

Abb. 3: Kraft-Weg-Beschreibung für ein visko-elastisches Maxwell-Kelvin-Voigt-Element. Das dreiparametrige Modell kann die gemessenen Kraft-Weg-Kurven approximativ beschreiben (σ: Kraft, x: Weg; μ_1, α, ω: Modellparameter).

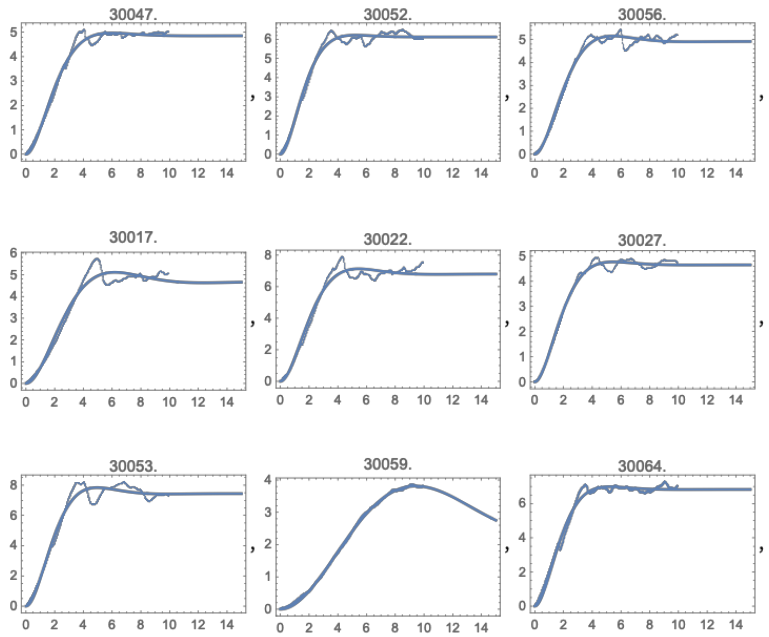

Abb. 4: Beispielhaft sind neun Fits des Maxwell-Kelvin-Voigt-Modells (glatte Kurven) an gemessene Kraft-Weg-Verläufe (verrauschte Kurven) von Äpfeln gezeigt. Die grobe Struktur wird gut erfasst; höherfrequente Schwingungsanteile (z. B. Fit 30053) bleiben unberücksichtigt.

Wahrscheinlichkeitsbasiertes Wasserverlust-Vorhersageschema für Trauben. Für Trauben wurde – gemeinsam mit D. Heger (TSN) – ein detailliertes, mehrstufiges Bayes'sches Schema zur Vorhersage des Wasserverlusts während der Lagerung ausgearbeitet. Es verbindet damit konkret die Bausteine Chemometrie, physikalische Modellierung und Bayes'sche Unsicherheitsquantifizierung zu einem in sich geschlossenen Vorhersage- und Klassifikationswerkzeug für den Digitalen Zwilling und besteht aus sieben Schritten:

1. ***Basis-Wahrscheinlichkeitsverteilung:*** Aus den Referenzmessungen wird mittels Bayes'scher Inferenz eine Basisverteilung (PDF/CDF) für den relativen Trockenmasseanteil ω der Trauben einer Lieferung geschätzt. Die Posterior-Verteilung der Verteilungsparameter μ ergibt sich aus N Messungen D = {ω_1, …, ω_N} zu der untenstehenden Gleichung,

$$P(\vec{\mu} \mid D) = \frac{\pi(\vec{\mu})}{P(D)} \prod_{i=1}^{N} K(\omega_i \mid \vec{\mu})$$

wobei π(μ) die Prior-Verteilung und K das Fehlermodell des chemometrischen Modells ist;

daraus folgt die Basisverteilung (Vorhersage-Prior)

$$P_B(\omega) = \int P(\omega \mid \vec{\mu})\, P(\vec{\mu} \mid D)\, d\vec{\mu}$$

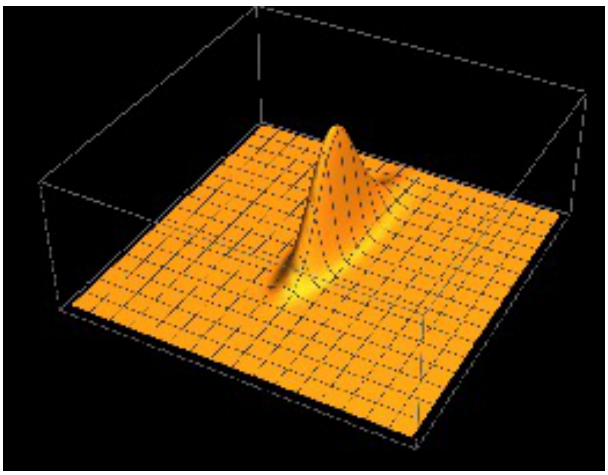

Abb. 5: Beispielhafte Wahrscheinlichkeitsdichte P(ω) über den relativen Trockenmasseanteil ω, wie sie als Basisverteilung des Schemas dient.

2. ***Chemometrisches Modell:*** Ein chemometrisches Modell verknüpft die spektral gemessenen Größen mit dem relativen Wassergehalt der einzelnen Frucht und liefert zugleich ein Modell für dessen Vorhersagefehler K – nach Einschätzung der Autoren der kritischste Schritt des gesamten Schemas.
3. ***Physikalisches Wasserverlustmodell:*** Der Wasserfluss J über die Traubenoberfläche wird als proportional zur Differenz der Wasserdampf-Partialdrücke innen (p_s, abhängig vom Wassergehalt: $p_s = \tau\, \omega$) und außen (p_e) angenommen:

$$\dot{\omega} = -J = -\kappa A\,(p_s - p_e) = -\kappa\tau A\,\omega + \kappa A\,p_e$$

Mit den Abkürzungen $\alpha := \kappa\,\tau\,A$ (relative Wasserverlustrate) und $\beta := p_e/\tau$ (Gleichgewichts-Wassergehalt) lautet die Lösung

$$\omega(t) = \omega_0\, e^{-\alpha t} + \beta(1 - e^{-\alpha t})$$

bzw. – falls α und β aus den verfügbaren Zeitreihen nicht getrennt identifizierbar sind ($\beta \to 0$) – die vereinfachte Form

$$\omega(t) = \omega_0\, e^{-\alpha t}$$

4. ***Bayes'sches Update-Verfahren:*** Neue Messwerte (z. B. entlang der Lieferkette) aktualisieren iterativ die Basisverteilung nach dem Satz von Bayes. Aus M neuen Messungen D_{new} und der bisherigen Posterior $P(\mu \mid D_{old})$ als neuem Prior ergibt sich die aktualisierte Posterior

$$P(\vec{\mu} \mid D_{\text{new}}) \;=\; \frac{P(\vec{\mu} \mid D_{\text{old}})}{P(D_{\text{new}})} \prod_{i=1}^{M} \int_0^1 K(\omega_i - \omega)\, P_B(\omega \mid \vec{\mu})\, d\omega$$

und daraus die aktualisierte Vorhersageverteilung (Predictive Posterior)

$$P_U(\omega) = \int P_B(\omega \mid \vec{\mu})\, P(\vec{\mu} \mid D_{\text{new}})\, d\vec{\mu}$$

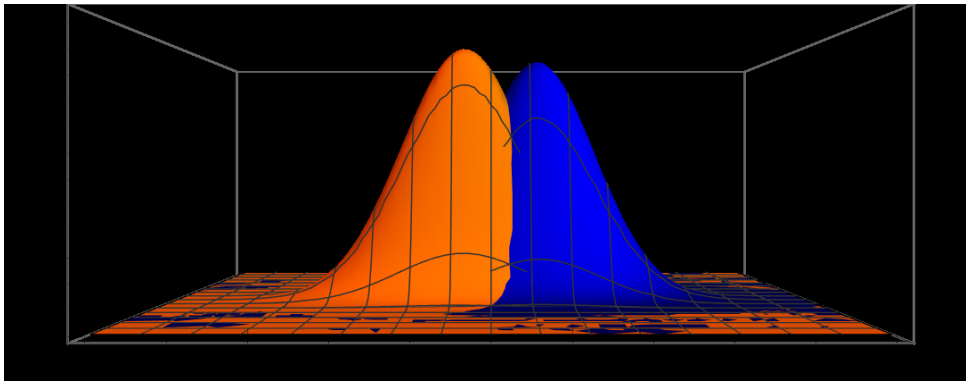

Abb. 6: Schematische Darstellung zweier überlagerter Wahrscheinlichkeitsverteilungen – etwa der Vorhersageverteilung vor (orange) und nach (blau) einem Bayes'schen Update-Schritt).

5. ***Zeitliche Propagation der Verteilung:*** Die zeitliche Entwicklung der Wassergehaltsverteilung folgt der Liouville-/Kontinuitätsgleichung

$$\partial_t P(\omega, t) + \partial_\omega(\dot{\omega}\, P(\omega, t)) = 0$$

die sich für das exponentielle Wasserverlustmodell mittels der Charakteristikenmethode geschlossen lösen lässt:

$$P(\omega, t \mid \alpha, \beta) = P_U\big((\omega - \beta)\, e^{\alpha t} + \beta\big) e^{\alpha t}, \qquad \omega \geq \beta$$

(bzw. $P(\omega,t \mid \alpha) = P_U(\omega\, e^{\alpha t})\, e^{\alpha t}$ für $\beta = 0$). Da die Rate α selbst unsicherheitsbehaftet ist, wird zusätzlich über deren Verteilung P(α) marginalisiert:

$$P(\omega, t) = \int P_U(\omega e^{\alpha t})\, P(\alpha)\, e^{\alpha t}\, d\alpha$$

Die Normierung $\int_0^1 P(\omega,t)\, d\omega = 1$ bleibt dabei für alle t erhalten.

6. ***Klassifikatorerstellung:*** Mit einem kritischen Wassergehalt ω_c und der bedingten kumulativen Verteilung

$$C(\omega_c, t \mid \alpha) = \int_0^{\omega_c} P_U(\omega e^{\alpha t})\, e^{\alpha t}\, d\omega = \int_0^{\omega_c e^{\alpha t}} P_U(y)\, dy$$

lassen sich zwei Klassen definieren – Klasse A ($\omega > \omega_c$, „noch genießbar/verkaufsfähig") und Klasse B ($\omega \leq \omega_c$) – mit den Wahrscheinlichkeiten $P(A,t) = 1 - C(\omega_c,t)$ und $P(B,t) = C(\omega_c,t)$. Über eine vorgegebene Akzeptanzwahrscheinlichkeit p_A lässt sich entweder zu festem $t = T$ die Klassenzugehörigkeit feststellen (die Lieferung ist „Klasse A", falls $P(A,T) \geq p_A$), oder umgekehrt der Übergangszeitpunkt $t(\alpha) = C^{-1}(p_A \mid \omega_c, \alpha)$ und dessen Verteilung $P(t) = \int \delta(t - C^{-1}(p_A \mid \omega_c, \alpha))\, P(\alpha)\, d\alpha$ bestimmen (z. B. Median und 5-/95-%-Perzentile). Für nicht scharf abgrenzbare Kategorien werden ergänzend unscharfe Zugehörigkeitsfunktionen (Fuzzy-Logik) $M_n(\omega)$: $\omega \rightarrow [0,1]$ mit

$$\sum_{n=1}^{N} M_n(\omega) = 1, \qquad P(n,t) = \int M_n(\omega)\, P(\omega,t)\, d\omega$$

eingeführt, die sich als bedingte Wahrscheinlichkeiten P(n | ω) ≡ M_n(ω) interpretieren lassen und fließende Übergänge zwischen Qualitätsklassen abbilden.

7. ***Iteratives Lernen vor Ort:*** Messungen am Auslieferungs-/Verkaufsort fließen über das Schema aus Schritt 4 verallgemeinert auf n Iterationen zurück in die Basisverteilung,

$$P_B^n(\omega) = \int P_B^{n-1}(\omega \mid \vec{\mu})\, P^n(\vec{\mu} \mid D^n)\, d\vec{\mu}$$

und verbessern so kontinuierlich die Vorhersagegüte – ganz im Sinne des „lernenden" Digitalen Zwillings (für P^0(μ | D^0) ≡ P(μ | D) aus Schritt 1 fällt dieser Schritt mit Schritt 4 zusammen).

Das Schema wurde anhand von *in-silico*-Demonstrationen mit 150 simulierten Traubenmessungen validiert (u. a. Vergleich der Posterior-Schätzung bei 20 vs. 80 Datenpunkten sowie Propagation der Verteilung über 4 bzw. 7 Tage) und stellt damit eine wesentliche, über die ursprüngliche knappe Zielbeschreibung („Modell für den Wasserverlust bei Trauben während der Lagerung") hinausgehende methodische Vertiefung dar – zugleich ein weiterer direkter Beitrag zu PZ7, da auch hier robuste Wahrscheinlichkeitsaussagen aus vergleichsweise kleinen Referenzdatensätzen abgeleitet werden.

AP2.2/AP2.3 – Botrytis-Keimungswahrscheinlichkeit

Es wurden erste Trainingsdatensätze zur Schimmelausbreitung (Botrytis) auf Trauben erhoben: Laborprotokolle zur Beimpfung mit Schimmelsporen, Sporengewinnung, Lagerungsbedingungen sowie Zeitreihen digitaler Mikroskopiebilder der Sporenkeimung wurden entwickelt bzw. aufgenommen, um Bilderkennungsmodelle zu trainieren und ein Modell für die Keimungswahrscheinlichkeit zu entwickeln. Die Arbeiten wurden durch eine Verzögerung bei der Gerätebeschaffung (lange Lieferzeiten) sowie durch eine Kontamination der Proben mit dem humanpathogenen Pilz Aspergillus Niger erschwert; mit Unterstützung von Prof. Matthias Hahn (Universität Kaiserslautern) wurden die Probengewinnung und Arbeitsprotokolle angepasst. Die automatisiert ausgewerteten Mikroskopiebilder zeigen eine deutliche Abhängigkeit der Keimungswahrscheinlichkeit von den Lichtverhältnissen. Leider konnten wir die Arbeiten an Botrytis nicht abschließen, da die Datengewinnung erheblich aufwendiger war als ursprünglich angenommen. Allerdings werden die etablierten Verfahren zu neuen, spezifischen Anträgen führen.

AP2.3/AP4.2 – Quantifizierung von Unsicherheiten / wahrscheinlichkeitsbasierte Qualitätsprüfung

UFR hat ein Schema entwickelt, das systematisch sowohl die Unsicherheiten der Messmethoden als auch die der Prognosemodelle bei Qualitätsprognosen berücksichtigt und den Schluss von der Stichprobe auf die Gesamtheit (Lieferung/Batch) ermöglicht. Demonstriert wurde dies am Beispiel der Apfelgrößenbestimmung: Aus zwei Steigen mit

insgesamt 74 Äpfeln (gemessen über das von TSN entwickelte RGB-Bild-Modul) musste mit Wahrscheinlichkeitsaussagen ermittelt werden, ob eine Lieferung die Handelsnorm-Toleranzen einhält – eine kombinatorisch sehr aufwendige Berechnung (z. B. ca. 17 Billionen Summanden bei N = 100, f = 10 fehlerhaften Früchten). Durch eine geschickte mathematische Transformation konnte die Rechenzeit um den Faktor 1000 beschleunigt werden, was Echtzeitfähigkeit für den Praxiseinsatz und Demonstratoren ermöglicht. Das in enger Zusammenarbeit mit TSN und BENE entwickelte Schema ist adaptiv (es lernt aus neuen Erfahrungen), auf zeitabhängige Prognosemodelle übertragbar und erlaubt zusätzlich die Bewertung, ob ein zerstörungsfreies Messverfahren ausreichend genau ist. Diese Arbeiten gehen nach eigener Einschätzung erheblich über die ursprünglich in AP2.3 vorgesehenen Arbeiten hinaus, haben sich aber als notwendiger Baustein für ein digitalisiertes Prüfverfahren erwiesen.

Vertiefung der Problemstellung:

- ***Grundproblem:*** Eine Stichprobe ist entweder konform mit einer Spezifikation oder nicht (dichotomes Merkmal). Aus der Beobachtung an N gezogenen Stichproben (z. B. „wie viele Äpfel sind zu klein/zu groß?“) soll auf die Eigenschaften der Gesamtlieferung (Batch) geschlossen werden. Unter der Hypothese, dass der Anteil fehlerhafter Früchte in der Gesamtlieferung p beträgt, folgt die Wahrscheinlichkeit, dabei genau f fehlerhafte Früchte unter N Stichproben zu ziehen, der Binomialverteilung

$$P(f \mid N, p) = \binom{N}{f} p^{f} (1-p)^{N-f}$$

deren kumulative Form

$$P(F \leq f \mid N, p) = \sum_{k=0}^{f} \binom{N}{k} p^{k} (1-p)^{N-k}$$

angibt, mit welcher Wahrscheinlichkeit höchstens f Ausreißer auftreten. Bereits für N = 100 und f = 10 ergeben sich (100 über 10) ≈ 1,73 × 10¹³ („ca. 17 Billionen“) zu summierende Möglichkeiten – der kombinatorische Kern des eingangs erwähnten Rechenaufwands.

- ***Bayes'sche Rückschlüsse:*** Mit Hilfe der kumulativen Binomialverteilung und des Satzes von Bayes (hier in der allgemeinen Form mit Ereignis A = „Spezifikation erfüllt“ und B = „Messdaten“):

$$P(A \mid B) = \frac{P(B \mid A)\ P(A)}{P(B)}$$

lässt sich von der Stichprobe auf die Gesamtlieferung schließen und die Wahrscheinlichkeit angeben, dass die Lieferung der Spezifikation entspricht bzw. nicht entspricht; eine Lieferung wird akzeptiert, wenn diese Wahrscheinlichkeit einen vorgegebenen Schwellenwert p_A (z. B. 0,8) übersteigt, was die Rate falsch-positiver Entscheidungen kontrolliert – eine Konstruktion, die strukturell genau der Klassifikator-Logik (kritischer Wert / Akzeptanzwahrscheinlichkeit p_A) des Wasserverlustschemas in AP2.2 entspricht.

- ***Berücksichtigung von Messfehlern:*** Da Messverfahren (z. B. die Abschätzung der Apfelgröße aus einem einfachen Mobiltelefonfoto, Vorhersagefehler ca. 3 mm) grundsätzlich fehlerbehaftet sind, muss dieser Vorhersagefehler explizit in die Modellierung einfließen.
- ***Sequenzielles Testen:*** Als praxisnahe Alternative zur Erhöhung der Stichprobengröße wurde eine sequenzielle Teststrategie untersucht und mit dem direkten Test großer Stichproben verglichen (z. B. Start mit 120 Äpfeln, bei Bedarf Fortsetzung mit weiteren 240 vs. direkter Test von 240 Äpfeln) – ein Ansatz, der die Prüfkosten in der Praxis deutlich senken kann, ohne die Aussagekraft wesentlich zu beeinträchtigen.

Diese Vertiefung zeigt, dass das Schema nicht nur konzeptionell, sondern auch in seiner mathematischen Herleitung und an realistischen Testszenarien im Konsortium kommuniziert und diskutiert wurde, und untermauert die Einschätzung, dass es sich gut publizieren lässt (vgl. Abschnitt 4 und 5).

Abweichungen von der ursprünglichen Planung

Eine Änderung der über Projektmittel zu beschaffenden Geräteliste wurde beantragt und genehmigt. Die Beschaffung der Botrytis-Ausrüstung verzögerte sich (Beschaffungsprozess, Lieferzeiten) und konnte erst 2024 weitgehend abgeschlossen werden; die zugehörigen Versuche wurden bis 2025 fortgeführt. Alle übrigen Arbeiten verliefen planmäßig. Änderungen der Zielsetzung waren zu keinem Zeitpunkt erforderlich.

3. Zusammenfassung

Über die Projektlaufzeit konnte UFR alle ihr zugewiesenen Ziele (PZ5, PZ7) sowie die geleiteten Arbeitspakete (AP1.2, AP2.2, AP3.2) im Wesentlichen plangemäß bzw. mit Erweiterungen erfüllen: umfangreiche, gut dokumentierte Referenzdatensätze für zwei Produktarten (Trauben, Äpfel), funktionsfähige chemometrische Modelle mit guter Vorhersagegüte für die meisten Qualitätsattribute, ein implementierter und getesteter lernender Digitaler Zwilling auf Basis hybrider Grey-Box-Modelle, ein bis zur Publikationsreife ausgearbeitetes siebenstufiges Bayes'sches Schema zur Vorhersage des Wasserverlusts von Trauben (gemeinsames Manuskript mit TSN, Mai 2025), ein innovativer hybrider Ansatz zur Festigkeitsbestimmung trotz unsicherer Referenzdaten (direkter Nachweis von PZ7), erste Modelle zur Botrytis-Keimung sowie – als Erweiterung über die ursprüngliche Planung hinaus – ein praxistaugliches, deutlich beschleunigtes und mathematisch detailliert hergeleitetes Schema zur wahrscheinlichkeitsbasierten Qualitätsprüfung unter Berücksichtigung von Mess- und Modellunsicherheiten. Die einzige nennenswerte zeitliche Abweichung betrifft die Botrytis-Arbeiten; inhaltlich war zu keinem Zeitpunkt eine Anpassung der Projektziele notwendig.

4. Verbreitung und Veröffentlichung

Konkret liegt bereits ein gemeinsam mit TSN erarbeitetes wissenschaftliches Manuskript vor: „Predicting Water Loss of Grapes“ (D. Heger, TSN, und C. Fleck, UFR, Stand Mai 2025), das in Abschnitt 2 (AP2.2) beschriebene siebenstufige Bayes’sche Vorhersageschema für den Wasserverlust von Trauben darstellt und mit *in-silico*-Demonstrationen validiert.

Wir planen dieses Verfahren gemeinsam zu veröffentlichen, allerdings müssen dazu noch zusätzliche Validierungsschritte durchlaufen werden.

Die mathematische Herleitung und Erprobung des Schemas zur wahrscheinlichkeitsbasierten Qualitätsprüfung (Abschnitt 2, AP2.3/AP4.2) soll gemeinsam mit Prof. Thorsten Schmidt von der Mathematischen Stochastik an der Universität Freiburg publiziert werden.

5. Ausblick

Die Arbeiten an Botrytis werden als Gebiet mit erheblichem Potenzial für eine wissenschaftliche Weiterführung eingeschätzt; ebenso lässt sich das entwickelte Schema zur wahrscheinlichkeitsbasierten Qualitätsprüfung gut publizieren und auf weitere, insbesondere zeitabhängige Prognoseprobleme übertragen. Im Projektverlauf wurden neue Kontakte zu Prof. Matthias Hahn (Universität Kaiserslautern) sowie zu Prof. Reinhard Fischer und Prof. Peter Nick (KIT Karlsruhe) geknüpft; UFR sieht hier erhebliches Potenzial in der Verbindung von biologischem Fachwissen mit den verfolgten quantitativen, mathematisch-statistischen Ansätzen und plant, bei passenden Ausschreibungen gemeinsame Projektskizzen einzureichen. Eine kommerzielle Verwertung durch UFR selbst ist nicht vorgesehen; der Schwerpunkt liegt auf wissenschaftlichen Publikationen und der Ausbildung von Promovierenden/Postdocs.