

Od krótkookresowego wskaźnika gotowości
dostawczej do globalnych modeli probabilistycznych:
analiza ryzyka w systemach z zapasem
zabezpieczającym i ocena metod uczenia
maszynowego z ograniczeniami dotyczącymi
ustalonych poziomów obsługi - skrócony referat

Jakub Wojtasik

20 maja 2026

Streszczenie

Referat przedstawia ekonomiczno-statystyczny problem wyznaczania zapasu zabezpieczającego w systemach, w których dostawca zobowiązuje się do utrzymania ustalonego poziomu obsługi mierzonego krótkookresowym wskaźnikiem gotowości dostawczej, tj. wskaźnikiem fill rate. Szczególne znaczenie mają tu umowy o poziomie usług, określane dalej jako Service Level Agreement (SLA), które w praktyce najczęściej występują w relacjach business-to-business (B2B), tj. między profesjonalnymi kontrahentami gospodarczymi. W takim układzie decyzja o poziomie zapasu nie jest wyłącznie decyzją operacyjną, lecz także instrumentem alokacji ryzyka, kosztu i odpowiedzialności za niewykonanie zobowiązania.

Punktem wyjścia jest luka między prognozowaniem popytu a decyzją zapasową. Modele predykcyjne są często estymowane pod kątem klasycznych miar dokładności prognoz, podczas gdy ostateczna ocena ekonomiczna i kontraktowa dotyczy zdolności do realizacji ustalonego poziomu obsługi przy możliwie niskim koszcie zapasu (Goltsos i in., 2022; Syntetos i in., 2010). Referat syntetyzuje wyniki dwóch powiązanych prac: artykułu dotyczącego analizy ryzyka w modelach typu basestock pod krótkookresowymi audytami fill rate (Wojtasik i in., 2026) oraz manuskryptu poświęconego ocenie globalnych modeli probabilistycznych w systemach order-up-to z ograniczeniami poziomu obsługi (Wojtasik, 2026).

1. Wstęp

Wystąpienie dotyczy problemu wyznaczania zapasu zabezpieczającego w systemach, w których poziom obsługi dostawcy jest rozliczany za pomocą krótkookresowego wskaźnika gotowości dostawczej, interpretowanego jako wskaźnik fill rate w skończonym horyzoncie oceny. Problem ten ma charakter ekonomiczny, ponieważ poziom zapasu bazowego determinuje koszt utrzymywania zapasów, koszt niedoboru oraz ryzyko niewykonania zobowiązania kontraktowego. Ma on również charakter statystyczny, ponieważ decyzja zapasowa jest funkcją niepewnego popytu estymowanego na podstawie skończonej próby obserwacji.

Znaczenie tego problemu jest szczególnie widoczne w relacjach między kontrahentami biznesowymi. SLA nie jest w takim przypadku ogólną deklaracją jakości obsługi, lecz elementem kontraktu regulującym powtarzalną współpracę nabywcy i dostawcy. Niedotrzymanie wymaganego poziomu obsługi nie stanowi wyłącznie incydentu operacyjnego, lecz może wpływać na koszty koordynacji, renegocjacje warunków, reputację dostawcy oraz trwałość relacji handlowej. Zapas zabezpieczający należy zatem interpretować jako narzędzie ograniczania ryzyka kontraktowego, a nie wyłącznie jako techniczny bufor popytu.

Punktem wyjścia jest niespójność między kryteriami stosowanymi w prognozowaniu popytu a kryteriami wykorzystywanymi do oceny decyzji zapasowych. W praktyce modele prognostyczne są często estymowane w celu minimalizacji klasycznych miar błędu predykcji, podczas gdy decyzje zapasowe są następnie wyznaczane w odrębnym module przy dodatkowych założeniach dotyczących rozkładu popytu lub błędu prognozy. Ostateczna ocena ekonomiczna następuje jednak przez wskaźnik poziomu obsługi, który nie jest bezpośrednim kryterium optymalizacji na etapie estymacji modelu. W konsekwencji model predykcyjnie dokładny nie musi być modelem decyzyjnie efektywnym (Goltsos i in., 2022; Syntetos i in., 2010).

Celem badawczym jest określenie, w jaki sposób narzędzia ekonometrii, statystyki matematycznej i probabilistycznego uczenia maszynowego mogą wspierać kosztowo efektywne projektowanie zapasu zabezpieczającego w systemach z ustalonym poziomem obsługi. W pierwszym artykule cel ten przyjmuje postać wyznaczania poziomu wartości zapasu zabezpieczającego w skończonym horyzoncie, analizy wpływu długości okresu przeglądu na poziom zapasu i wariancję jego estymatora oraz konstrukcji narzędzi kwantyfikacji ryzyka niespełnienia wymaganego poziomu obsługi. W drugim artykule cel zostaje rozszerzony na porównanie lokalnych i globalnych modeli probabilistycznych w ramach wspólnego problemu decyzyjnego order-up-to.

Zasadnicza hipoteza pierwszego artykułu głosi, że stosowanie formuł fill rate właściwych dla nieskończonego horyzontu do systemów rozliczanych w skończonym horyzoncie prowadzi do systematycznego zawyżenia poziomu zapasu zabezpieczającego.

Hipoteza ta ma bezpośrednią interpretację ekonomiczną: niewłaściwe dopasowanie definicji wskaźnika obsługi do mechanizmu rozliczenia kontraktu skutkuje nadmiernym zaangażowaniem kapitału w zapasach. Druga hipoteza zakłada, że długość okresu przeglądu wpływa zarówno na wymagany poziom zapasu, jak i na wariancję jego estymatora. Trzecia hipoteza dotyczy możliwości wykorzystania dystrybucyjnie wolnych ograniczeń probabilistycznych, w szczególności nierówności Hoeffdinga, do wyznaczania ryzyka niewykonania zobowiązania przy ograniczonej historii popytu.

Hipotezy drugiego artykułu odnoszą się do relacji między architekturą modelu, funkcją celu treningowego i efektywnością decyzji zapasowej. Zakłada się, że globalne modele probabilistyczne, trenowane na heterogenicznych panelach jednostek asortymentowych, określanymi dalej jako stock keeping unit (SKU), mogą uzyskać korzystniejszą granicę efektywności między poziomem zapasu a poziomem obsługi niż lokalne modele klasyczne. Jednocześnie przewaga ta powinna zależeć od reżimu poziomu obsługi, ponieważ przy ekstremalnych wartościach fill rate lokalne modele mogą lepiej odwzorowywać ogonowe własności pojedynczych szeregów. Dodatkowo zakłada się, że modele trenowane bezpośrednio względem straty zapasowej powinny lepiej odpowiadać ekonomicznemu celowi kontraktu niż modele trenowane wyłącznie względem ogólnej miary jakości prognozy.

2. Przegląd literatury

Podstawowym kontekstem badawczym jest literatura dotycząca rozdzielenia prognozowania i decyzji zapasowych. Problem ten został określony przez Goltsos i in. (2022) jako luka między prognozowaniem a kontrolą zapasów. Zgodnie z tą perspektywą poprawa dokładności prognozy nie musi prowadzić do obniżenia kosztów zapasów ani do poprawy poziomu obsługi. Wartość informacji prognostycznej powinna być zatem oceniana przez jej wpływ na decyzję i wynik ekonomiczny, a nie wyłącznie przez metryki predykcyjne.

Drugim istotnym nurtem jest literatura dotycząca skończonego horyzontu fill rate. Thomas (2005) wykazał, że krótkookresowy fill rate ma odmienne własności niż jego długookresowy odpowiednik, ponieważ w skończonym horyzoncie wskaźnik obsługi jest zmienną losową. Tan i in. (2017) sformalizowali zależność między horyzontem oceny a poziomem zapasu, wskazując, że tradycyjne formuły uzupełnień mogą prowadzić do nadmiernego zapasu w systemach podlegających okresowym audytom. Omawiane badanie nad modelami basestock rozwija ten nurt przez wyprowadzenie formuł dla popytu gamma i konstrukcję procedury nieparametrycznej dla przypadku nieznanego rozkładu popytu.

Trzeci kontekst stanowi teoria kosztów transakcyjnych. W ujęciu Coase (1937) transakcje rynkowe generują koszty wyszukiwania, negocjowania i egzekwowania kontraktów. Williamson (1979, 1985) rozwinął tę intuicję w teorię struktur mechanizmów

zarządzania relacją kontraktową (governance), w której wybór formy koordynacji zależy od specyfiki aktywów, niepewności i częstotliwości transakcji. W systemach SLA parametry kontraktu, takie jak długość okresu przeglądu, docelowy fill rate oraz struktura sankcji, określają sposób alokacji ryzyka między nabywcą a dostawcą.

W relacjach między kontrahentami biznesowymi znaczenie tych mechanizmów jest szczególnie wyraźne. SLA może być interpretowane jako hybrydowa forma governance, w której formalne zobowiązania kontraktowe współistnieją z monitoringiem, normami relacyjnymi i mechanizmami reputacyjnymi. Literatura wskazuje, że w złożonych relacjach dostawczych mechanizmy informacyjne oraz normy współpracy mogą odgrywać istotną rolę w ograniczaniu skutków niepewności i oportunistów (Holmström i Roberts, 1998; Wilding i Humphries, 2006). Z tej perspektywy model zapasowy nie jest wyłącznie narzędziem operacyjnym, lecz elementem infrastruktury informacyjnej wykorzystywanej do zarządzania relacją kontraktową.

Istotne jest również powiązanie analizowanego problemu z literaturą principal-agent. Nabywca nie obserwuje w pełni ani działań dostawcy, ani jakości jego informacji o przyszłym popycie, dlatego SLA pełni funkcję mechanizmu wyrównywania bodźców przez mierzalny standard wykonania (Jensen i Meckling, 1976). Zapas zabezpieczający stanowi w tym ujęciu koszt ponoszony przez dostawcę w celu ograniczenia prawdopodobieństwa niewykonania kontraktu.

Drugi artykuł wpisuje się ponadto w literaturę predict-then-optimize oraz decision-focused learning. Tradycyjny paradygmat forecast-first opiera się na założeniu separowalności prognozowania i optymalizacji. W warunkach asymetrycznej funkcji straty i kontraktowego ograniczenia poziomu obsługi założenie to może być nieadekwatne, ponieważ model minimalizujący funkcję scoringową nie musi minimalizować kosztu decyzji zapasowej (Bergsma i in., 2025; Elmachtoub i Grigas, 2022). Podejście decision-focused learning stanowi odpowiedź na tę niespójność, ponieważ łączy kryterium decyzji bezpośrednio do procesu treningu modelu.

3. Metody

Pierwszy artykuł wykorzystuje model basestock ze skończonym horyzontem oceny fill rate. Dostawca ustala poziom zapasu bazowego, który ma zapewnić zaspokojenie określonej części popytu w okresie przeglądu. W pracy wyprowadzono dokładne formuły dla popytu o rozkładzie gamma oraz zaproponowano procedurę dla przypadku nieparametrycznego (Wojtasik i in., 2026). Rozkład gamma jest traktowany jako klasyczne założenie dystrybucyjne w analizie popytu, natomiast procedura nieparametryczna odpowiada sytuacjom, w których postać rozkładu popytu nie może zostać wiarygodnie ustalona na podstawie dostępnych danych.

Kluczowym elementem metodologicznym jest analiza asymptotyczna estymatora poziomu zapasu zabezpieczającego. Zastosowanie metody delta pozwala wyznaczyć rozkład asymptotyczny estymatora oraz zbadać wpływ długości okresu przeglądu na wariancję estymacji. W ujęciu statystycznym oznacza to analizę własności estymatora funkcjonału decyzyjnego przy skończonej próbie. W ujęciu ekonomicznym wynik ten pozwala określić, czy decyzja oparta na estymacie punktowej zapewnia dostateczną kontrolę ryzyka, czy też konieczne jest wykorzystanie bardziej konserwatywnego poziomu zapasu, np. wyznaczonego na podstawie górnego krańca przedziału ufności.

W warunkach ograniczonej liczby obserwacji zastosowano nierówność Hoeffdinga. W analizowanym ujęciu służy ona do odwrotnego odwzorowania dostępnego zasobu informacji na poziom ryzyka, który można uzasadnić bez przyjmowania określonej parametrycznej rodziny rozkładów popytu. W kontekście relacji między kontrahentami biznesowymi procedura ta zwiększa przejrzystość decyzji zapasowej, ponieważ pozwala uzasadnić poziom zapasu nie arbitralnym buforem bezpieczeństwa, lecz formalnym ograniczeniem probabilistycznym.

Drugi artykuł wykorzystuje model order-up-to z krótkookresowym ograniczeniem fill rate. Wszystkie analizowane metody są oceniane w tym samym problemie decyzyjnym: na podstawie prognozy popytu wyznaczany jest poziom zapasu, a następnie decyzja jest oceniana względem zrealizowanego popytu oraz docelowego poziomu obsługi. Porównanie obejmuje cztery klasy modeli: model ARIMA jako lokalny benchmark statystyczny; Generalized Autoregressive Score (GAS) jako lokalną metodę semiparametryczną z aktualizacją score-driven; DeepAR jako globalny model głębokiego uczenia probabilistycznego; oraz Light Gradient Boosting Machine (LightGBM) jako globalny model gradient boosting z probabilistycznym modelowaniem reszt (Box i in., 2015; Creal i in., 2013; Ke i in., 2017; Patton i in., 2019; Salinas i in., 2020; Wojtasik, 2026).

Projekt empiryczny rozdziela dwa wymiary analizy: architekturę modelu oraz funkcję celu treningowego. W paradygmacie forecast-first model optymalizuje jakość prognozy probabilistycznej, a dopiero później prognoza zostaje przekształcona w poziom zapasu. W paradygmacie decision-focused parametry modelu są optymalizowane bezpośrednio względem straty właściwej dla decyzji zapasowej. Pozwala to określić, czy przewaga danej metody wynika z architektury modelu, wykorzystania informacji przekrojowej między SKU, czy zgodności funkcji celu z ekonomicznym kryterium kontraktu.

Miary ewaluacyjne mają charakter decyzyjny. Analiza wykorzystuje krzywe efektywności zapas-obsługa, miarę średniego kosztu znormalizowanego popytem, określaną jako mean total cost per unit (MTCPU), średni ranking, odsetek najlepszych wyników oraz empiryczny fill rate. Zastosowanie tych miar jest konsekwencją przyjętej perspektywy badawczej: w systemie z ustalonym poziomem obsługi jakość modelu

powinna być oceniana przez koszt osiągnięcia wymaganego poziomu obsługi, a nie wyłącznie przez dokładność predykcyjną.

4. Dyskusja

Uzyskane wyniki wskazują, że niedopasowanie horyzontu definicji fill rate do horyzontu rozliczenia kontraktu prowadzi do wymiernych konsekwencji ekonomicznych. Stosowanie długookresowych formuł w krótkookresowych audytach SLA skutkuje nadmiernym poziomem zapasu zabezpieczającego. Źródłem nieefektywności nie jest zatem wyłącznie błąd estymacyjny, lecz użycie niewłaściwej definicji funkcjonału decyzyjnego względem instytucjonalnego mechanizmu rozliczenia. W relacjach między kontrahentami biznesowymi nadmierny zapas może zostać wbudowany w ceny, marże, warunki kontraktu lub zdolność dostawcy do obsługi innych odbiorców.

Istotną rolę odgrywa długość okresu przeglądu. Wydłużenie horyzontu oceny zwiększa zarówno wymagany poziom zapasu, jak i wariancję jego estymatora. Z ekonomicznego punktu widzenia okres przeglądu powinien być traktowany jako zmienna kontraktowa determinująca podział ryzyka, koszt kapitału i ekspozycję dostawcy na niewykonanie zobowiązania. W relacjach B2B oznacza to, że długość audytu wpływa nie tylko na poziom zapasu, lecz także na intensywność monitorowania i warunki koordynacji między stronami.

Wyniki dotyczące nierówności Hoeffdinga wskazują na możliwość budowy reguł decyzyjnych odpornych na niepełną wiedzę o rozkładzie popytu. Przy krótkich historiach danych klasyczne metody parametryczne mogą prowadzić do nadmiernej pewności co do poziomu ryzyka. Dystrybucyjnie wolne ograniczenie pozwala natomiast sformułować regułę konserwatywną, lecz statystycznie uzasadnioną. W kontekście kontraktowym zmniejsza to arbitralność decyzji o poziomie bufora bezpieczeństwa.

W drugim artykule wykazano, że globalne modele probabilistyczne mogą poprawiać użyteczność decyzyjną w systemach z krótkookresowym fill rate, jednak skala tej poprawy zależy od reżimu poziomu obsługi. DeepAR osiąga korzystny profil efektywności zapas, obsługi, a w wariancie decision-focused uzyskuje najniższą stratę znormalizowaną popytem dla poziomów obsługi $\tau \in \{0.9, 0.95, 0.99\}$. Oznacza to, że informacja przekrojowa zawarta w panelu SKU ma wartość ekonomiczną wtedy, gdy prowadzi do niższego kosztu realizacji określonego poziomu obsługi.

Wyniki nie wspierają jednak tezy o bezwarunkowej dominacji modeli globalnych. Przy ekstremalnie wysokich poziomach obsługi lokalne modele mogą odzyskiwać konkurencyjność, ponieważ lepiej adaptują się do specyficznych własności ogonowych poszczególnych szeregów. Wniosek ten ma znaczenie dla zarządzania portfelem SKU: wybór modelu powinien być warunkowany reżimem ryzyka, kosztem niedoboru, wartością relacji z odbiorcą oraz wymaganym poziomem obsługi.

Krzywe efektywności zapas, obsługa wskazują ponadto na malejące krańcowe korzyści z dodatkowego zapasu. Przy niskich i średnich poziomach zapasu wzrost zapasu istotnie poprawia empiryczny fill rate, natomiast przy wysokich poziomach obsługi efekt dodatkowej jednostki zapasu ulega osłabieniu. W kategoriach ekonomicznych jest to problem wyboru punktu na granicy efektywności, w którym krańcowy koszt dodatkowego zapasu jest równoważony przez krańcową redukcję ryzyka niedoboru lub niewykonania kontraktu.

Zakres analizy pozostawia jednocześnie kilka otwartych problemów badawczych. Oba artykuły koncentrują się na wskaźniku P2 fill rate, natomiast alternatywne miary poziomu obsługi, takie jak cycle service level lub type-I fill rate, pozostają poza zakresem analizy. Dalsze badania mogą zatem dotyczyć innych funkcjonałów decyzyjnych, innych funkcji strat oraz ich własności identyfikacyjnych i asymptotycznych.

Drugim ograniczeniem jest brak jawnego modelowania niepewności czasu dostawy. Analiza empiryczna wykorzystuje szeregi jednowymiarowe bez eksplicytnej niepewności lead time. W praktyce losowy czas realizacji zamówienia może być równie istotnym źródłem ryzyka jak losowy popyt. Rozszerzenie modelu o stochastyczny lead time wymagałoby połączenia niepewności popytu, niepewności dostaw oraz konsekwencji kontraktowych niedotrzymania poziomu obsługi.

Ograniczeniem ekonomicznym jest status teorii kosztów transakcyjnych. W obecnym ujęciu pełni ona funkcję ramy interpretacyjnej, a nie formalnie estymowanego modelu empirycznego. Kolejny etap badań mógłby polegać na testowaniu, czy parametry kontraktów, częstotliwość audytów, struktura sankcji, historia współpracy oraz stopień współzależności stron wpływają na wybór modelu zapasowego i koszty niewykonania SLA.

5. Wnioski

Wyniki obu artykułów prowadzą do wniosku, że projektowanie zapasu zabezpieczającego w systemach z ustalonym poziomem obsługi powinno być analizowane jako problem decyzyjny osadzony w kontekście kontraktowym. Artykuł dotyczący krótkookresowych audytów fill rate dostarcza narzędzi do wyznaczania poziomu tego zapasu oraz kontroli ryzyka jego niedoszacowania w skończonym horyzoncie. Artykuł dotyczący globalnych modeli probabilistycznych pokazuje, że wybór algorytmu i funkcji celu treningowego wpływa na granicę efektywności między poziomem zapasu a poziomem obsługi.

Najważniejszy wkład polega na przesunięciu kryterium oceny modelu z dokładności prognozy na kosztowo efektywną realizację zobowiązania kontraktowego. W systemach SLA, typowych dla relacji między kontrahentami biznesowymi, prognoza jest jedynie wejściem do decyzji, której konsekwencją jest koszt zapasu, ryzyko niedo-

boru i ryzyko naruszenia relacji gospodarczej. Właściwym kryterium oceny modelu jest zatem jego użyteczność decyzyjna, a nie wyłącznie metryka predykcyjna.

Zastosowania praktyczne wynikają z tej interpretacji. Po pierwsze, wyniki mogą wspierać projektowanie i negocjowanie SLA przez powiązanie docelowego fill rate, długości okresu przeglądu i tolerowanego poziomu ryzyka z wymaganym zapasem zabezpieczającym. Po drugie, mogą służyć do kalibracji systemów planowania zasobów przedsiębiorstwa, określanych jako enterprise resource planning (ERP), i modułów planowania zapasów, zwłaszcza tam, gdzie formuły długookresowe są stosowane do krótkookresowych audytów i generują nadmierny poziom zapasu. Po trzecie, dystrybucyjnie wolne ograniczenia ryzyka mogą wspierać decyzje w warunkach krótkich historii popytu, typowych dla nowych produktów, mniejszych dostawców lub niestabilnych rynków.

W dużych portfelach SKU wyniki uzasadniają podejście segmentowe. Globalne modele probabilistyczne mogą poprawiać efektywność decyzji w heterogenicznych panelach, lecz ekstremalne cele obsługi wymagają ostrożności i mogą uzasadniać wykorzystanie metod lokalnych lub hybrydowych. Wybór modelu powinien zatem zależeć od reżimu poziomu obsługi, kosztu niedoboru, zmienności popytu, wartości relacji z odbiorcą oraz konsekwencji kontraktowych niewykonania zobowiązania.

Ostatecznie przeprowadzone badania wskazują, że metody statystyczne i ekonometryczne powinny być projektowane w ścisłym powiązaniu z ekonomiczną funkcją instytucji, w której są stosowane. W analizowanym przypadku instytucją tą jest SLA, a narzędziem decyzyjnym reguła wyznaczania zapasu zabezpieczającego. Kluczowe pytanie nie dotyczy więc tego, który model jest najdokładniejszy predykcyjnie, lecz tego, który model najlepiej wspiera kosztowo efektywną, statystycznie uzasadnioną i kontraktowo wiarygodną decyzję o poziomie zapasu.

Bibliografia

- Bergsma, R., C. de Ruijt i S. Bhulai (2025). „A systematic review of machine learning approaches in inventory control optimization”. W: *Operations Research Perspectives* 15, s. 100367. DOI: 10.1016/j.orp.2025.100367.
- Box, G. E. P., G. M. Jenkins, G. C. Reinsel i G. M. Ljung (2015). *Time Series Analysis: Forecasting and Control*. 5 wyd. Wiley.
- Coase, R. H. (1937). „The nature of the firm”. W: *Economica* 4.16, s. 386–405. DOI: 10.1111/j.1468-0335.1937.tb00002.x.
- Creal, D., S. J. Koopman i A. Lucas (2013). „Generalized autoregressive score models with applications”. W: *Journal of Applied Econometrics* 28.5, s. 777–795. DOI: 10.1002/jae.1279.

- Elmachtoub, A. N. i P. Grigas (2022). „Smart predict, then optimize”. W: *Management Science* 68.1, s. 9–26. DOI: 10.1287/mnsc.2020.3922.
- Goltsos, T. E., A. A. Syntetos, C. H. Glock i G. Ioannou (2022). „Inventory-forecasting: Mind the gap”. W: *European Journal of Operational Research* 299, s. 397–419. DOI: 10.1016/j.ejor.2021.07.040.
- Holmström, B. i J. Roberts (1998). „The boundaries of the firm revisited”. W: *Journal of Economic Perspectives* 12.4, s. 73–94. DOI: 10.1257/jep.12.4.73.
- Jensen, M. C. i W. H. Meckling (1976). „Theory of the firm: Managerial behavior, agency costs and ownership structure”. W: *Journal of Financial Economics* 3.4, s. 305–360. DOI: 10.1016/0304-405X(76)90026-X.
- Ke, G., Q. Meng, T. Finley, T. Wang, W. Chen, W. Ma, Q. Ye i T.-Y. Liu (2017). „LightGBM: A highly efficient gradient boosting decision tree”. W: *Advances in Neural Information Processing Systems*. T. 30, s. 3146–3154.
- Patton, A. J., J. F. Ziegel i R. Chen (2019). „Dynamic semiparametric models for expected shortfall and Value-at-Risk”. W: *Journal of Econometrics* 211.2, s. 388–413. DOI: 10.1016/j.jeconom.2018.10.008.
- Salinas, D., V. Flunkert, J. Gasthaus i T. Januschowski (2020). „DeepAR: Probabilistic forecasting with autoregressive recurrent networks”. W: *International Journal of Forecasting* 36.3, s. 1181–1191. DOI: 10.1016/j.ijforecast.2019.07.001.
- Syntetos, A. A., M. Z. Babai, J. Davies i D. Stephenson (2010). „Forecasting and stock control: A study in a wholesaling context”. W: *International Journal of Production Economics* 127, s. 103–111. DOI: 10.1016/j.ijpe.2010.05.001.
- Tan, Y. i in. (2017). „Finite-horizon fill rate in inventory systems”. W: *Operations Research Letters*. Please verify full bibliographic details against the source document.
- Thomas, D. J. (2005). „Measuring item fill-rate performance in a finite horizon”. W: *Manufacturing & Service Operations Management* 7, s. 74–80.
- Wilding, R. i A. S. Humphries (2006). „Understanding collaborative supply chain relationships through the application of the Williamson organisational failure framework”. W: *International Journal of Physical Distribution & Logistics Management* 36.4, s. 309–329. DOI: 10.1108/09600030610672064.
- Williamson, O. E. (1979). „Transaction-cost economics: The governance of contractual relations”. W: *Journal of Law and Economics* 22.2, s. 233–261. DOI: 10.1086/466942.
- (1985). *The Economic Institutions of Capitalism*. Free Press.
- Wojtasik, J. (2026). „Integrating Probabilistic Demand Forecasting and Inventory Decisions: Evaluating Machine Learning, Deep Learning, and Semiparametric Approaches under Short-Term Fill Rate Service Level Constraints”. Manuscript

under review in Information Sciences. Available at SSRN. DOI: 10.2139/ssrn.6416928. URL: <https://ssrn.com/abstract=6416928>.

Wojtasik, J., J. Bruzda i B. Abbasi (2026). „Risk analysis in basestock inventory systems under short-term fill rate audits”. W: *IISE Transactions* 58.5, s. 586–604. DOI: 10.1080/24725854.2025.2519789.